

Geostatistical Characteristics of the Structure of Spatial Variation of Electrical Power in the National 110 KV Network Including Results of Variogram Model Components Filtering

Authors

Barbara Namysłowska-Wilczyńska
 Artur Wilczyński

Keywords

electrical power, superficial variation, geostatistical modelling, ordinary kriging, lognormal kriging, filtering the components in models of variograms

Abstract

The paper provides results of analysing the superficial variability of electrical power using two geostatistical methods – lognormal kriging and ordinary kriging. The research work was to provide detailed characterization and identification of the electrical load variability structure at nodes of a 110 kV network over the whole territory of Poland having been analyzed on the basis of results from kriging techniques applied. The paper proposes the methodology using two techniques of modelling and estimating average values Z^* of electrical powers, i.e. lognormal kriging and ordinary kriging.

The input data for calculations were electrical powers at nodes of 110 kV network related to the same time moment, i.e. 11:00 a.m. in summer and winter seasons.

Kriging calculations were made for various variants of examinations. Filtering was carried out for assumed complex theoretical models of semivariograms of electrical powers, which means their dividing into several models components of the covariance (nugget effect, 1 spherical model, 2 spherical model), which were filtered out successively. Then, estimations were made for average values Z^* of powers while particular components are passed over.

The results of analyses made with considering particular components of semivariograms models were shown in raster maps providing distributions of estimated average values Z^* of electrical powers. This allowed the orientation of variations in values of this parameter, both over the territory of the whole country and in time domain, for two seasons – summer and winter, and also when various models components were assumed of semivariograms of the loads. Detailed analysis of spatial-time variability of average values Z^* of electrical loads over the country allowed to identify their range and nature of variability.

DOI: 10.12736/issn.2300-3022.2015106

1. Introduction

In the planning process of development and operation of the power grid infrastructure adequate to the demand for electric power at a given point in time and in a given area, spatial modelling of electrical loads' distribution is applied, followed by their estimation and forecasting. In order to meet the power system economic efficiency and safety conditions the questions have to be answered: where the loads increase, how much they change with changed locations, and what is the geographical direction of these changes?

Space-time models of power intake variation distribution developed for a given area and each hour of the day may also be used in so-called energy management, i.e. the shaping of both the supply side, so called Supply Side Management – SSM, as well as the demand side, so called Demand Side Management – DSM. This is particularly important in the case of an increasing share of small energy sources, including non-conventional ones, the operation of which features a high degree of uncertainty. In article¹ geostatistical methods were used, previously applied by the authors in spatial modelling and forecasting of the

¹ Fragments of this article were presented at the VIIth National Scientific Conference INFOBAZA 2014 Inspiration • Integration • Implementation, organized by Gdańsk University of Technology, Institute of Oceanology of the Polish Academy of Sciences and TASK IT Centre, in Gdańsk – Sopot, 8–10 Sept. 2014 and published in paper [1].

Analysed parameter	Sample size n	Value X_{\min} [MW]	Value X_{\max} [MW]	Average value \bar{X} [MW]	Standard deviation S [MW]	Coefficient of variation V [%]
electric power (summertime, 11:00 hours)	1123	0.10	277.54	16.02	31.34	195.58
electric power (wintertime, 11:00 hours)	1132	0.12	356.18	21.13	40.57	191.99

Tab. 1. Basic statistical parameters of electric power in the 110 kV power network (based on the original data)

Analysed parameter	Sample size n	Value X_{\min} [MW]	Value X_{\max} [MW]	Average value \bar{X} [MW]	Standard deviation S [MW]	Coefficient of variation V [%]
electric power (summertime, 11:00 hours)	1022	-2.30	5.53	1.90	0.93	48.83
electric power (wintertime, 11:00 hours)	1029	-2.12	5.67	2.19	0.95	43.24

Tab. 2. Basic statistical parameters of electric power in the 110 kV power network (logarithmized ln data)

phenomena emerging in 2D and 3D systems, including areas such as geology and mining [2, 3, 4, 5], environmental studies [6], energy [7–15], economy [14, 15], and hydrogeology [16].

The main aim of this study was to characterize and recognize the structure of electrical load variation across the country, analysed in the example of details of power in 110 kV grid nodes, in the light of the results obtained by using the variogram functions and kriging techniques, taking into account also the results of filtering of the tested process' individual components. A research methodology was proposed that employed two geostatistical techniques for estimation of average electric powers Z^* , i.e. ordinary kriging and lognormal kriging, using a variety of sample search neighbourhoods – unique and moving. In order to more accurately identify the phenomenon under study, various components of the power demand variation process of (shown in variogram models and raster maps) were filtered out using ordinary kriging.

The spatial variation of electrical power was analysed using ISATIS (version 2015), a statistical software package by Geovariances Firm, Avon – Cedex, France.

2. Basic statistics of electrical load in the 110 kV power network

Subject to the study was space and time diversity, analysed on the basis of a set of sample data of electric power measurements in 110 kV grid nodes covering the whole country. The data were associated with two specific moments in time, namely with the summer and winter periods, 11:00 hours. For the sake of data confidentiality the year is not specified. The authors' intention was to present a research methodology for estimating the average electrical powers, using geostatistical tools. In the study the content was used of databases of the X and Y coordinates of the grid nodes (measurement points), and of electrical powers P in these nodes. The numbers of the measurement points were

1,123 and 1,132 for the summertime and wintertime, respectively [7]. At the initial stage of the analysis the main statistical parameters for the summer and winter morning peaks were assessed (Tab. 1), determined on the basis of the original data. Due to the high positive skewness of the analysed process the basic statistics were calculated based on the logarithmized data (ln) (Tab. 2). The minimum, maximum and average electric powers are clearly higher in the wintertime (Tab. 1). Whereas the coefficients of power variation V for the whole country are similar for both periods, indicating the extremely high variation of power.

It was noted after the conversion of original values to logarithmized values that the above described regularity of the basic power statistics (min., max. and average) is maintained, with higher values for the winter period (Tab. 2). The standard deviations are almost identical. The coefficients of variation V differ insignificantly for the two periods, and that in the summertime is slightly higher.

3. Histograms of electrical load distribution in the 110 kV power network

Calculation of electric power distribution histograms was the next stage of the analysis (Fig. 1–4). The electrical power distribution histograms drawn up on the basis of the original data are asymmetrical (single-wing), with dominant modal classes, which is confirmed by the high positive skewness coefficients g_1 : 4.43 (summertime) – 4.67 (wintertime) (Fig. 1, 3). The slenderness histogram of the distributions is evidenced by the kurtosis coefficients g_2 : 25.85 (summertime) – 29.10 (wintertime). In contrast, the logarithmized values (ln) distribution histograms are similar to the Gaussian distribution for both study periods (Fig. 2, 4), while the skewness coefficients g_1 are in the range of 0.33–0.085, and the kurtosis coefficients g_2 are in the range of: 5.68–5.95.




Fig. 1. Distribution histogram of the original powers [MW] in 110 kV network nodes – summertime, 11:00 hours




Fig. 2. Distribution histogram of the logarithmized (ln) powers [MW] in 110 kV network nodes – summertime, 11:00 hours

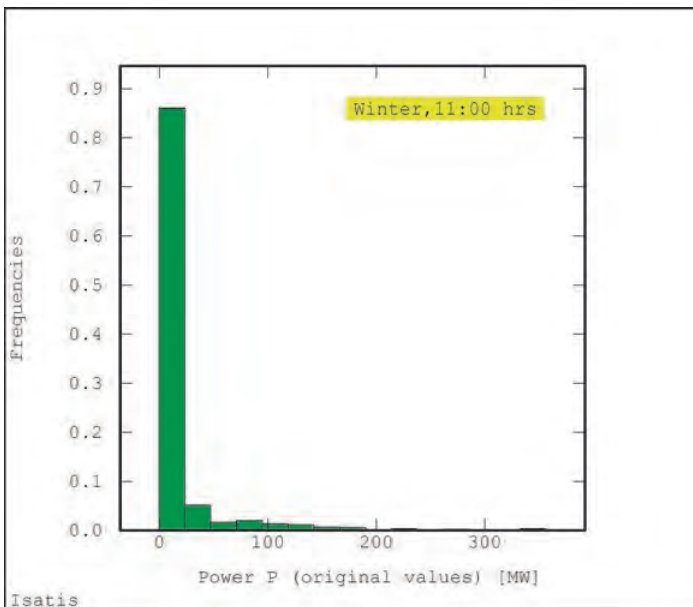


Fig. 3. Distribution histogram of the original electric powers [MW] in 110 kV network nodes – wintertime, 11:00 hours




Fig. 4. Distribution histogram of the logarithmized (ln) powers [MW] in 110 kV network nodes – wintertime, 11:00 hours

4. Methods of modelling of electrical loads spatial distribution

In order to estimate the spatial variation of power in 110 kV grid network nodes geostatistical methods were used, such as the variogram function and two estimation techniques – ordinary kriging and lognormal kriging (in block and point modification). Kriging calculations were made taking into account the unique and moving “neighbourhoods” (sample search subareas), in various analysis variants.

A process was carried out of filtering the power variation structure characterized by complex theoretical models describing power semivariogram courses. This process involves the separation of adopted models into several components (e.g. the nugget effect, 1 spherical model, 2 spherical model), which are subsequently filtered. This means that the average estimated powers Z^* are estimated in subsequent steps.

In practice, the spherical model is one of those most widely used to approximate empirical semivariogram courses in the Euclidean space, not larger than 3 [18].

Successively filtered out in the study were individual components of the adopted theoretical semivariogram models. Also calculated were the differences between the average powers Z^* representing the power variation's individual components. Additionally, the nugget effect was determined, which is the variation process' random factor.

The C_0 nugget effect is a visible discontinuity in the course of empirical semivariogram (at the starting point of graph $\gamma(h)$ [18]. This effect is caused by measurement errors or micro-nest structures smaller than the sampling distance, or by both causes. At the beginning of the semivariogram graph the value of function $\gamma(h)$ is always 0, however, in the absence of C_0 effect it aims to a positive value of C_0 significantly greater than 0. C_0 effect indicates the presence of the effect on the occurrence of local variation, which means rapid fluctuation in the electrical power.

4.1. Variogram function

Empirical variogram (semivariogram) that describes correlation of the studied variables, i.e. electric powers distributed over an area (in 2D), is represented by the following formula [8, 17, 18]:

$$\gamma^*(h) = \frac{1}{2n_h} \cdot \sum_{i=1}^{n_h} [z(x_i + h) - z(x_i)]^2 \quad (1)$$

where:

$z(x_i + h)$, $z(x_i)$ – powers in points x_i and $x_i + h$, and therefore spaced by distance h ; n_h – number of pairs $(x_i, x_i + h)$ of powers in points spaced by distance h , used in the calculation of semivariogram function $\gamma^*(h)$.

Empirical variogram courses describe the nature and degree of variation of the regionalised variable under consideration, i.e. powers in 110 kV network nodes.

4.2. Ordinary kriging technique

In the estimation process the ordinary kriging was used, which serves to estimate the average Z^* in a point location (ordinary point kriging) or in the centre of a block (ordinary block kriging) [10, 17, 18]. This technique allows estimating the point or block average in a node of the elementary square or rectangular grid (block centre) as the weighted average Z^* calculated on the basis of values measured in its local neighbourhood, i.e. in the sample search area, for the centre of an ellipse or circle placed in the node within the block. At the same time, with each estimated average Z^* (kriging estimate), the standard (kriging) estimation deviation σ_k or kriging variance σ_k^2 is calculated.

Weighted (moving) average Z^* is estimated after the following formula:

$$Z_k^* = \sum_{i=1}^n w_{ik} z_i \quad (2)$$

where:

z_i – analysed parameter, i.e. electric power, in point i , for $i = 1, \dots, n$;
kriging weighting factor (weight) assigned to sample i .

With the so called kriging system of equations (estimations) [6] it becomes possible to determine the weighting factors w_{ik} , assigned to data sampled within an estimated area and in its vicinity. Then they allow one to calculate the average error, called kriging error, the variance of which is given by:

$$\sigma_k^2 = \sum w_{ik} \bar{\gamma}(S_i, A) + \lambda - \bar{\gamma}(A, A) \quad (3)$$

where:

w_{ik} – kriging weighting factor (weight) assigned to sample i ;
 $\bar{\gamma}(A, A)$ – average of the variogram function between any two points in block A ;
 $\bar{\gamma}(S_i, A)$ – average of the variogram function between sampled values S_i and points in block A , λ – Lagrange multiplier.

Kriging variance σ_k^2 depends on the sample positions relative to the location to be estimated, and the parameters of the adopted empirical variogram theoretical model.

4.3. Lognormal kriging technique

Lognormal kriging (LK), also known as logarithmic kriging, serves to estimate the averages based on data characterized by high skewness, with lognormal distribution, for example. three-parametric (logarithms of the data, plus a constant) [10]. Original data, converted to natural logarithms $\ln[Z]$ are normally distributed. Lognormal kriging is popular in geostatistical studies, whereby highly diversified data are present in the sample subpopulation. If one of them appears in a small dataset, it causes a disproportionate effect. If used to estimate lognormal data, this kriging technique produces kriging variances below those of simple kriging. Usually observed is a charge (underestimation) of calculation results in the order of 5–7% [18].

5. Modelling of electrical power variograms

In Tab. 3–4 the geostatistical parameters and theoretical model types are listed, used to approximate the empirical variogram courses calculated on the basis of the original (Fig. 5–6) and logarithmized (\ln) (Fig. 7–8) power values. A characteristic feature of the semivariogram function $\gamma(h)$ courses calculated on the basis of the logarithmized data (\ln) and approximated with theoretical functions is their very good consistency (Fig. 7–8), much better than that of the semivariograms calculated from the original data (Fig. 5-6). In general, a model composed of one or two functions, i.e. the spherical function and nugget effect, was adopted for the approximation. This applies to measurements in the summer and winter periods alike. The nugget effect C_0 and sill variance C reach higher values in the wintertime, whereas the ranges of influence a (short-scale variation) in the semivariograms are comparable for both analysed periods (Tab. 3–4). The term of C_0 nugget effect is discussed in Chapter 4. The C_0 effect and partial variance C' taken together give the total sill variance C that represents the overall variation of the analyzed variable, i.e. electrical power.

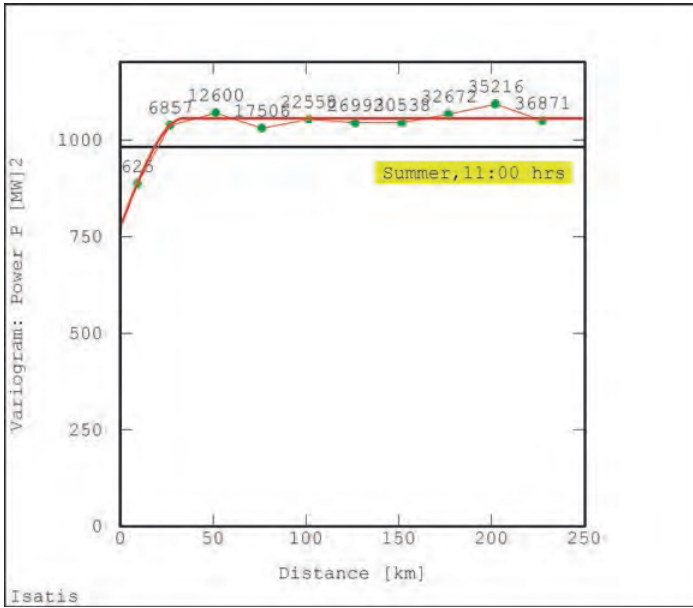


Fig. 5. Semivariogram of the original powers [MW] in 110 kV network nodes, approximated with a theoretical model – summertime, 11:00 hours

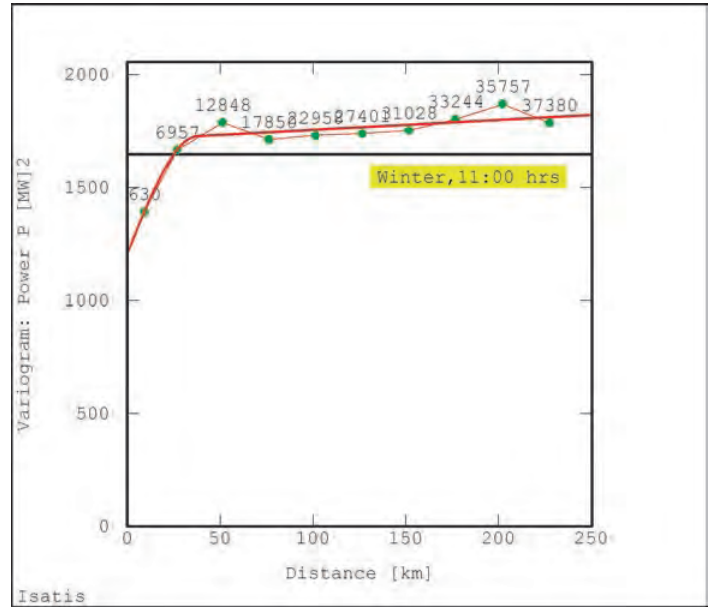


Fig. 6. Semivariogram of the original powers [MW] in 110 kV network nodes, approximated with a theoretical model – wintertime, 11:00 hours

The variance sill C is the upper limit of the adopted variogram model, possible to achieve at long distances, for the large arguments transitive variogram type [18]. The variogram range of influence a for a spherical model is the distance at which the

model reaches its maximum – the sill variance C (sill). The range a means that up to this distance there is a measurable correlation with adjacent sample values.

Analysed period	Nugget effect C_0 [MW]²	Partial variance C [MW]²	Total sill variance C [MW]²	Range of influence a [km]	Model type
Summertime 11:00 hrs	259.1096	246.9215 27.0395	533.0705	39 39	Nugget effect 1 spherical model 2 spherical model
Wintertime 11:00 hrs	400.7893	376.1724 54.6925	831.6541	34 81	Nugget effect 1 spherical model 2 spherical model

Tab. 3. Geostatistical parameters of 110 kV node load semivariogram models (calculations based on the original data)

Analysed period	Nugget effect C_0 [MW]²	Partial variance C [MW]²	Total sill variance C [MW]²	Range of influence a [km]	Model type
Summertime 11:00 hrs	0.6104	0.1949 0.0824	0.8877	33 70	Nugget effect 1 spherical model 2 spherical model
Wintertime 11:00 hrs	0.6482	0.2753	0.9235	32	Nugget effect

Tab. 4. Geostatistical parameters of 110 kV network nodes load semivariogram models (calculations based on the logarithmized data)


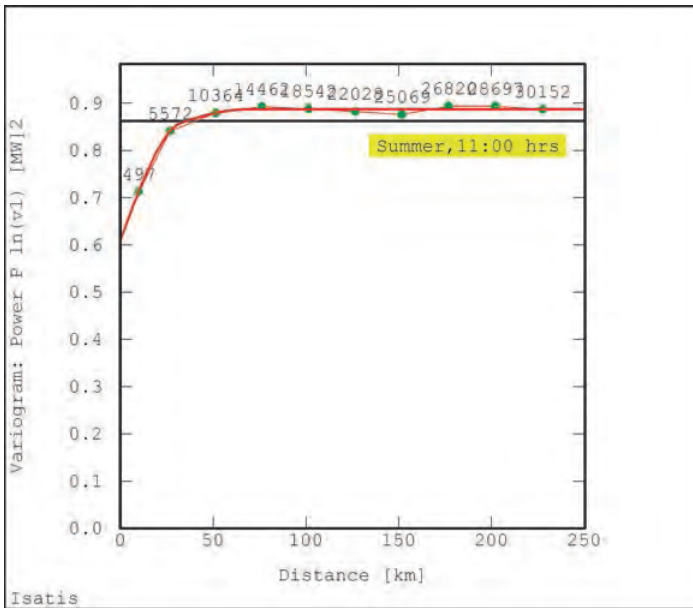


Fig. 7. Semivariogram of the logarithmized (ln) powers [MW] in 110 kV network nodes, approximated with a theoretical model – summertime, 11:00 hours

Fig. 8. Semivariogram of the logarithmized (ln) powers [MW] in 110 kV network nodes, approximated with a theoretical model – wintertime, 11:00 hours

6. Spatial distributions of power with the use of kriging techniques

Calculations with the use of ordinary kriging and lognormal kriging were made for various neighbourhood variants, i.e. subject to the adoption of the following sample search area

parameters $1 \times 1 \times 10$, $4 \times 8 \times 3$, and for fixed (unique) neighbourhood. In the latter case this means that all data from an analysed area are taken into account when estimating the estimated averages Z^* in each elemental grid node (Tab. 5 and 6).

Analysed parameter	Number of grid nodes N	Value X_{min} [MW]	Value X_{max} [MW]	Average value \bar{X} [MW]	Standard deviation S [MW]	Coefficient of variation V [%]
summertime, 11:00 hrs						
Moving neighbourhood $1 \times 1 \times 10$	4995	2.68 (6.97) *	122.11 (21.48)	11.14 (12.99)	10.33 (2.82)	92.70 (21.73)
Moving neighbourhood $4 \times 8 \times 3$	4995	2.81 (6.91)	117.29 (21.48)	11.11 (12.83)	9.60 (2.88)	86.36 (22.46)
Fixed neighbourhood	4995	0.37 (6.87)	112.19 (14.85)	11.68 (11.99)	8.03 (1.91)	68.73 (15.89)
wintertime, 11:00 hrs						
Moving neighbourhood $1 \times 1 \times 10$	4995	4.03 (8.79)	156.44 (26.58)	14.81 (16.26)	12.68 (3.38)	85.61 (20.82)
Moving neighbourhood $4 \times 8 \times 3$	4995	4.14 (8.71)	146.50 (26.58)	14.75 (16.02)	11.52 (3.47)	78.13 (21.67)
Fixed neighbourhood	4995	4.21 (8.67)	143.09 (18.53)	15.37 (15.08)	9.80 (2.33)	63.77 (15.47)

* values in parentheses are the standard estimation deviation σ_k

Tab. 5. Global statistics of estimated powers Z^* in the 110 kV power network; ordinary kriging

For the summer period comparable maximum estimated averages Z^* were obtained for two neighbourhood types: moving $1 \times 1 \times 10$ and $4 \times 8 \times 3$. These values were slightly lower for the unique neighbourhood (Tab. 5).

Also, the mean values calculated from the estimated averages Z^* do not significantly differ for the two neighbourhood variants (moving: $1 \times 1 \times 10$ and $4 \times 8 \times 3$), while for the unique neighbourhood the value was a little higher. The high coefficients of variation V testify to the high variability of power in the summertime, while their lowest values were obtained for the unique neighbourhood in both periods – summer and winter.

In the wintertime the highest and the lowest Z^* maxima resulted from the adoption of moving neighbourhood $1 \times 1 \times 10$ and the unique neighbourhood, respectively. It is opposite with regard to the minima (Tab. 5), although in the analysed variants the differences between them are small. Significantly lower coefficients of variation V were obtained for the unique neighbourhood. The coefficient of variation V obtained for moving neighbourhood $1 \times 1 \times 10$ indicated high power variability.

Calculations with the use of lognormal kriging were made taking into account moving neighbourhood in the aforementioned two sample search area variants (Tab. 6). The Z^* minima do not differ much from those obtained by the ordinary kriging method, while the Z^* maxima are much lower, in the summertime and wintertime alike. This may indicate that the ordinary kriging method better reflects the true nature of the electrical loads variation in the entire country (Tab. 5). The highest Z^* maxima were obtained for moving neighbourhood $4 \times 8 \times 3$, which relates to the summer and winter periods. The highest coefficients of variation V were obtained for moving neighbourhood $1 \times 1 \times 10$ and both seasons under consideration.

The Z^* averages estimated with the use of the two estimation techniques and taking into account moving neighbourhood ($1 \times 1 \times 10$, $4 \times 8 \times 3$) are shown in raster maps; for ordinary kriging (Fig. 9a, 9b), and for lognormal kriging (Fig. 10a, 10b).

It can be concluded from comparison of the images of spatial power distribution variation in the summertime (11:00 hrs) obtained with the use of the ordinary (Fig. 9a and 9b) and lognormal (Fig. 10a and 10b) kriging techniques that the former technique better reflects the nature of changes in the analysed process. In this case the raster images more specifically reflect the differentiation of estimated powers Z^* . At the same time it can be concluded that the use of moving sample search neighbourhood gives more accurate results (Fig. 9a, 9b).

Similar observations can be made based on the power raster map images for the winter period drawn up using both techniques (Fig. 11a, 11b, 12a and 12b). The use of ordinary kriging also gives a more accurate picture of changes in the analysed process, except that both sample search neighbourhoods, i.e. $1 \times 1 \times 10$ and $4 \times 8 \times 3$ give very similar results (Fig. 11a, 11b, 12a and 12b).

The Z^* averages were estimated using ordinary kriging for three analysed variants, and therefore various numbers of elementary grid nodes covering the area of Poland concerned, were included in the calculation. This is due to the procedure adopted for the search of samples for the determination of estimated averages Z^* for individual grid nodes. In the unique neighbourhood case all samples were included in the estimation of individual nodes ($N = 5775$), in the case of moving neighbourhood ($N = 4995$, variant $4 \times 8 \times 3$), i.e. up to max. 32 samples, min. 12 samples, and in the case of moving neighbourhood ($N = 5224$, variant $1 \times 1 \times 10$), i.e. up to max. 10 samples, and min. 1 sample. Thus, in some grid nodes there were not enough samples to estimate the average Z^* , and hence they were not calculated for the nodes.

Shapes of the histograms of estimated averages Z^* distributions analysed for several kriging neighbourhood variants indicate (Fig. 13a–14c) that consideration of the unique neighbourhood in the calculation provides the opportunity to more accurately reflect individual subpopulations of estimates Z^* of electrical powers P . If a moving neighbourhood is adopted with various different sample search parameters (Fig. 13a–13b, 14b–14c),

Analysed parameter	Number of grid nodes N	Value X_{\min} [MW]	Value X_{\max} [MW]	Average value \bar{X} [MW]	Standard deviation S [MW]	Coefficient of variation V [%]
summertime, 11:00 hrs						
Moving neighbourhood $1 \times 1 \times 10$	4995	2.70 (0,32) *	49.49 (1.28)	10.16 (0.51)	4.83 (0.14)	47.51 (27.05)
Moving neighbourhood $4 \times 8 \times 3$	4995	3.63 (0,31) *	66.23 (0.79)	10.28 (0.47)	4.21 (0.09)	41.02 (18.20)
Fixed neighbourhood	4995	3.63 (0.31)	66.14 (0.79)	10.28 (0.47)	4.21 (0.09)	40.98 (18.20)
wintertime, 11:00 hrs						
Moving neighbourhood $1 \times 1 \times 10$	4995	4.03 (0.34)	68.53 (0.77)	14.21 (0.51)	6.25 (0.06)	44.00 (12.82)
Moving neighbourhood $4 \times 8 \times 3$	4995	4.84 (0.32)	86.09 (0.77)	14.06 (0.49)	5.17 (0.08)	36.76 (15.68)
Fixed neighbourhood	4995	5.70 (0.32)	43.29 (0.48)	14.21 (0.44)	2.86 (0.03)	20.11 (7.42)

* values in parentheses are the standard estimation deviation σ_k

Tab. 6. Global statistics of estimated powers in the 110 kV power network; lognormal kriging

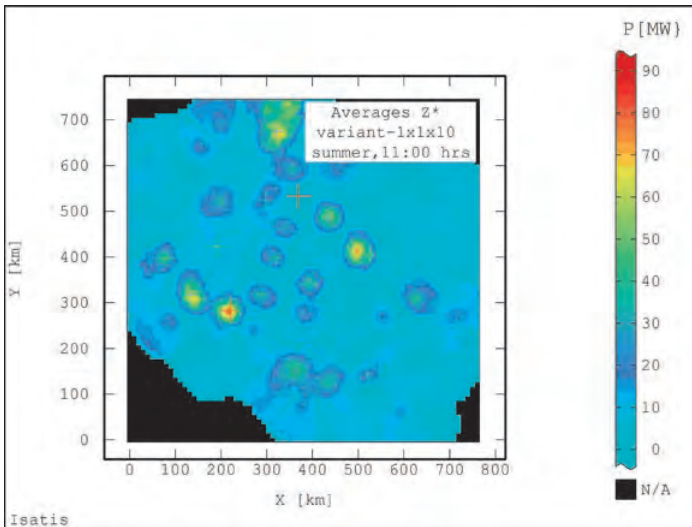


Fig. 9a. Raster map of the distribution of estimated average powers Z^* – summertime, 11:00 hours; ordinary block kriging (moving sample search neighbourhood – $1 \times 1 \times 10$)

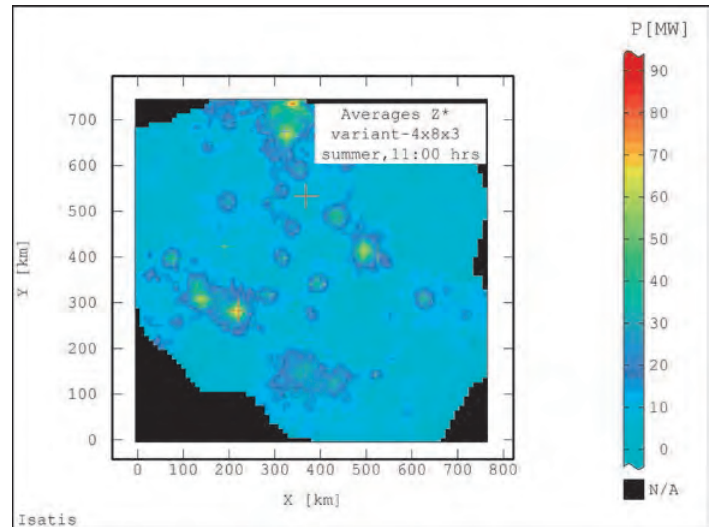


Fig. 9b. Raster map of the distribution of estimated average powers Z^* – summertime, 11:00 hours; ordinary block kriging (moving sample search neighbourhood – $4 \times 8 \times 3$)

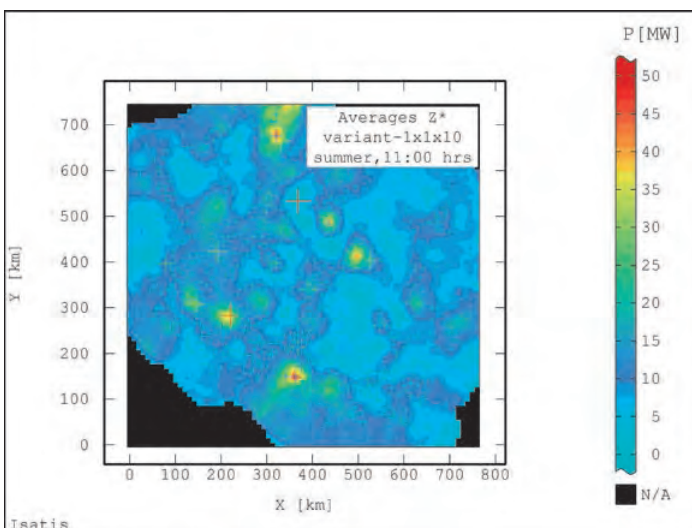


Fig. 10a. Raster map of the distribution of estimated average powers Z^* – summertime, 11:00 hours; ordinary block kriging (moving sample search neighbourhood – $1 \times 1 \times 10$)

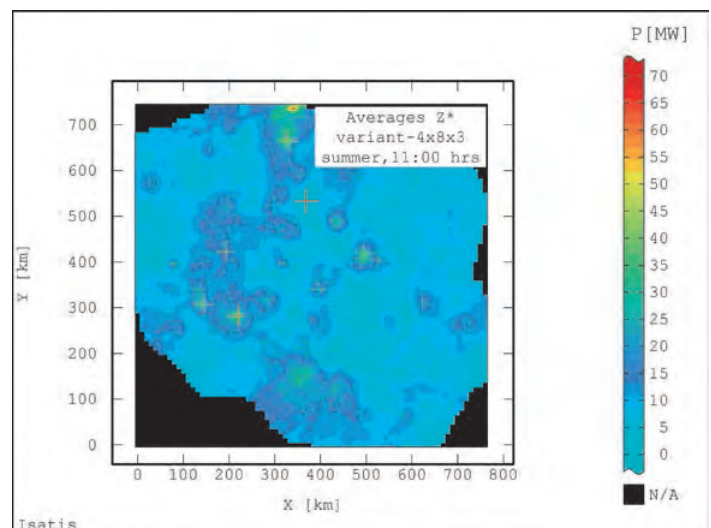


Fig. 10b. Raster map of the distribution of estimated average powers Z^* – summertime, 11:00 hours; ordinary block kriging (moving sample search neighbourhood – $4 \times 8 \times 3$)

extremely asymmetrical, single-winged distributions histograms are obtained. In comparison with the summertime histogram with dominant 1. modal class (Fig. 13c), in the wintertime histogram 2. modal classes clearly prevail, with only a slight predominance of higher average powers Z^* (Fig. 14a).

7. Filtering of components of electrical load variogram models using ordinary kriging

Results of filtering the individual components of electrical power semivariogram models made with the use of ordinary kriging, pointed as well as in a moving neighbourhood ($4 \times 8 \times 3$), are presented in Tab. 7 and 8.

The filtering resulted in the following raster maps of the power P distribution in the summer and winter seasons:

- raster map of the distribution of averages Z^* (v1)
- raster map of the distribution of averages Z^* , after the activation of filtering the component with short scale of spherical model (v2)
- raster map of the distribution of averages Z^* , after the activation of filtering the component with large scale of spherical model (v2)
- raster map of the distribution of averages Z^* , i.e. differences $v3 = v1 - v2$
- raster map of the distribution of averages Z^* , after the activation of filtering the random component – nugget effect C_0 .

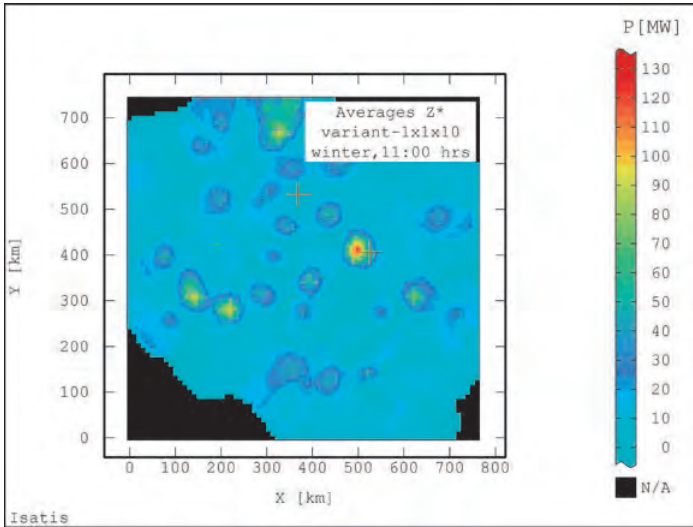


Fig. 11a. Raster map of the distribution of estimated average powers Z^* – wintertime, 11:00 hours; ordinary block kriging (moving sample search neighbourhood – $1 \times 1 \times 10$)




Fig. 11b. Raster map of the distribution of estimated average powers Z^* – wintertime, 11:00 hours; ordinary block kriging (moving sample search neighbourhood – $4 \times 8 \times 3$)

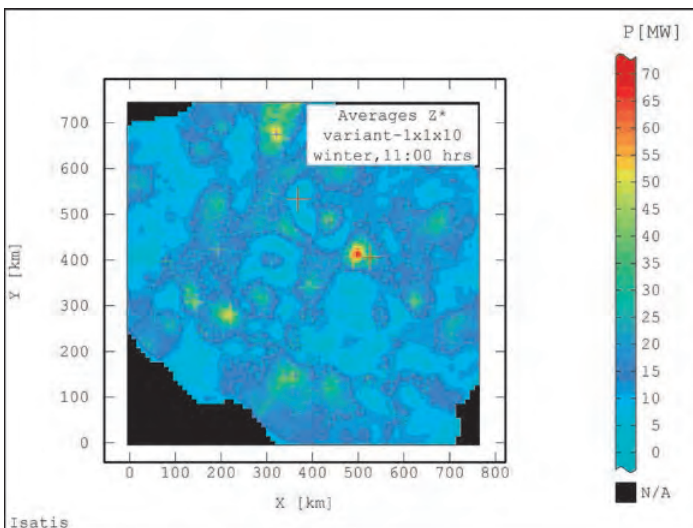


Fig. 12a. Raster map of the distribution of estimated average powers Z^* – wintertime, 11:00 hours; ordinary block kriging (moving sample search neighbourhood – $1 \times 1 \times 10$)

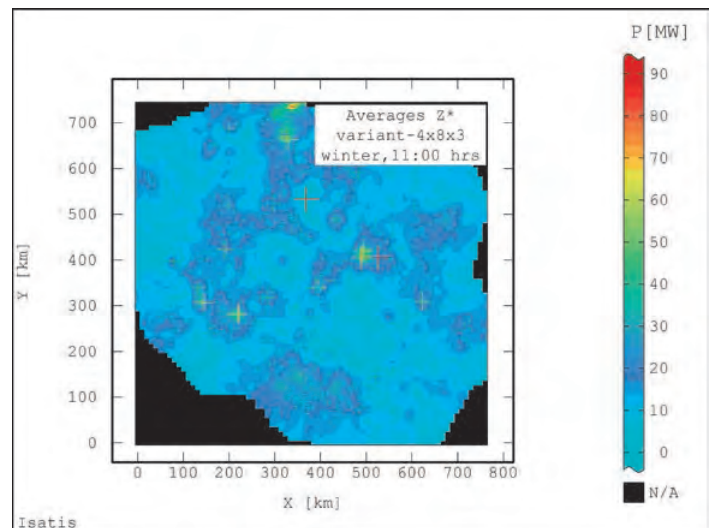


Fig. 12b. Raster map of the distribution of estimated average powers Z^* – wintertime, 11:00 hours; ordinary block kriging (moving sample search neighbourhood – $4 \times 8 \times 3$)

The map of the distribution of estimated averages Z^* of powers P , calculated with the use of ordinary point kriging, provided a reference for the analysis. It was compared with the aforementioned maps, drawn up after the filtering activation. Also calculated was a map of the distribution of differences $v_3 = v_1 - v_2$, i.e. estimated averages $Z^* - v_1$, and the averages Z^* determined for the components corresponding to the complex (spherical) model, approximating the courses of empirical power semivariograms – v_2 .

Filtering of nugget effect C_0 alone does not change the image of the total variation, because the use of kriging in itself is an action that filters the effect C_0 out, and leads to smoothing

and alignment of variation. The purpose of this operation is to demonstrate some differences that appear only when nodes of the adopted elementary grid do not overlap with positions of the estimating data, i.e. the data entering the estimation.

It should be remembered that the kriging estimates (estimated averages Z^* and standard estimation deviations σ_k) were calculated at nodes of the elementary grid covering the area in question, in this case Poland, whereas the power measurements were not always taken in these places. Therefore, filtering should be helpful in identifying the locations where the nugget effect C_0 reveals reflecting a higher power P .




Fig. 13a Histogram of the distribution of estimated average powers Z^* [MW] in 110 kV network nodes – summertime, 11:00 hrs; ordinary kriging, number of elementary grid nodes $N = 4995$, moving sample search neighbourhood $4 \times 8 \times 3$ ($X_{\min} = 3$, $X_{\max} = 117$, $\bar{X} = 11$, $S = 10$)




Fig. 13b. Histogram of the distribution of estimated average powers Z^* [MW] in 110 kV nodes – summertime, 11:00 hrs; ordinary kriging, number of elementary grid nodes $N = 5224$, moving sample search neighbourhood $1 \times 1 \times 10$ ($X_{\min} = 3$, $X_{\max} = 122$, $\bar{X} = 11$, $S = 10$)

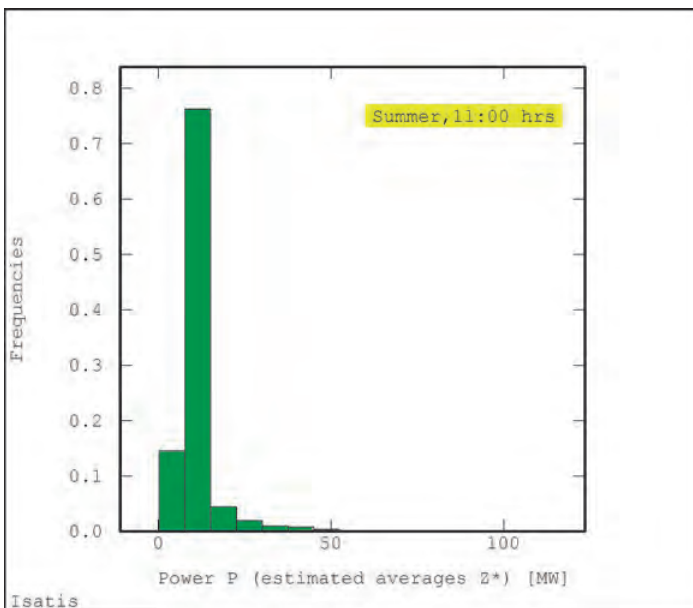


Fig. 13c. Histogram of the distribution of estimated average powers Z^* [MW] in 110 kV nodes – summertime, 11:00 hrs; ordinary kriging, number of elementary grid nodes $N = 5775$, unique neighbourhood ($X_{\min} = 0$, $X_{\max} = 112$, $\bar{X} = 12$, $S = 7$)

By analysing the distribution raster maps (Fig. 15a–16c) and scatter graphs of the total estimated averages Z^* and the averages Z^* representing the first component of the complex theoretical model (1. spherical model) of the variogram, a high

correlation was established between these values, $r = 0.624$ (summertime) and $r = 0.719$ (wintertime) (Fig. 17a–18c). However, in the case of analysing the interrelation between the total estimated averages Z^* and the averages Z^* representing the second component of this model (2. spherical model), it can be seen that this is the strongest correlation, as indicated by the correlation coefficients $r = 0.959$ (summertime) and $r = 0.99$ (wintertime) (Fig. 17c–18c). This shows that the total electrical power variability is better reflected by the spherical model that captures large-scale changes combined with nugget effect C_0 , as shown by the semivariogram courses (Fig. 5–8), especially for the winter period. Considering the fact that the modelling was done for a large area, i.e. the whole country, it seems obvious. Scatter graphs of the total estimated averages Z^* and the averages Z^* corresponding to nugget effect C_0 , as calculated for the two considered moments in time, evidence very high correlation of these values ($r = 0.97$ for summertime, $r = 0.99$ for wintertime).

8. Summary

The paper presents a methodology for analysis and modelling of the spatial variation of electrical powers, which employs two estimation techniques – ordinary kriging and lognormal kriging. As the optimal method of estimating the average electrical powers in the 110 kV grid should be considered the ordinary kriging combined with filtering of individual components of the adopted models of empirical semivariograms of the powers. The research approach proposed in the analysis of spatio-temporal variation, i.e. filtering of components of semivariogram load models with the use of ordinary kriging, is an original

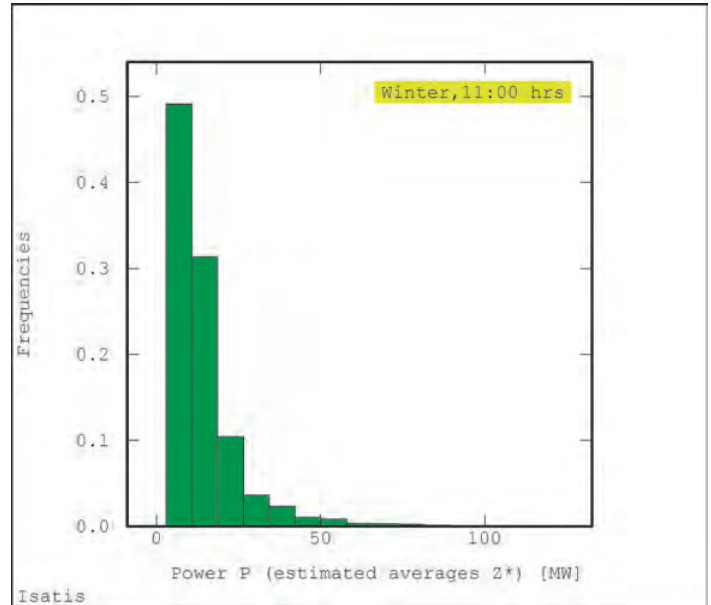



Fig. 14a. Histogram of the distribution of estimated average powers Z^* [MW] in 110 kV nodes – summertime, 11:00 hrs; ordinary kriging, number of elementary grid nodes $N = 4995$, moving sample search neighbourhood $4 \times 8 \times 3$ ($X_{\min} = 4$, $X_{\max} = 146$, $\bar{X} = 15$, $S = 12$)

Fig. 14b. Histogram of the distribution of estimated average powers Z^* [MW] in 110 kV nodes – summertime, 11:00 hrs; ordinary kriging, number of elementary grid nodes $N = 5224$, moving sample search neighbourhood $1 \times 1 \times 10$ ($X_{\min} = 3$, $X_{\max} = 156$, $\bar{X} = 14$, $S = 13$)

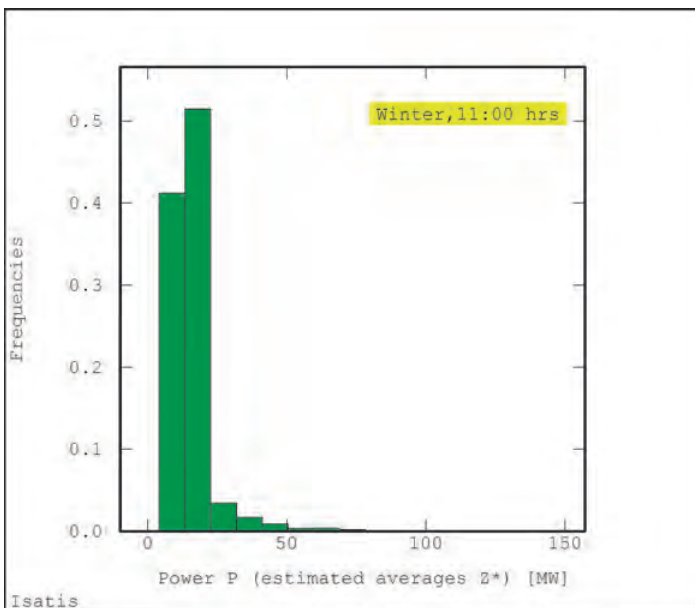


Fig. 14c. Histogram of the distribution of estimated average powers Z^* [MW] in 110 kV nodes – wintertime, 11:00 hrs; ordinary kriging, number of elementary grid nodes $N = 5775$, unique neighbourhood ($X_{\min} = 4$, $X_{\max} = 143$, $\bar{X} = 15$, $S = 9$)

research methodology, so far not applied in the modelling of spatial variation of electrical power.

The results of filtering of the process of space-time variation of electrical loads shown on the distributions raster maps enabled recognition of the ranges and nature of changes in power in the entire country, as well as in time, in two seasons of the year – summer and winter, and identification of the impact of the dominant component of the overall power variation.

Filtered parameter	Number of grid nodes N	Value X_{min} [MW]	Value X_{min} [MW]	Average value \bar{X} [MW]	Standard deviation S [MW]	Coefficient of variation V [%]
Total estimated average Z^* (v1)	4995	2.6856	122.1101	11.1403	10.3270	92.70
Average Z^* for complex model (1 spherical + 2 spherical) (v2)	4995	3.3480	91.5816	11.1389	6.4261	57.69
Difference $v3 = v1 - v2$	4995	0.0000	97.8747	4.6040	7.5227	163.39
Nugget effect C_0	4995	2.8130	117.2879	11.1107	9.5952	86.36

Tab. 7. Statistical parameters of the filtered values, i.e. components of semivariogram models of power in the 110 kV network, using ordinary kriging (summertime, 11:00 hrs)

Filtered parameter	Number of grid nodes N	Value X_{min} [MW]	Value X_{min} [MW]	Average value \bar{X} [MW]	Standard deviation S [MW]	Coefficient of variation V [%]
Total estimated average Z^* (v1)	4995	4.1435	146.4984	14.7485	11.5229	78.1291
Average Z^* for complex model (1 spherical + 2 spherical) (v2)	4995	4.1418	106.7878	14.7857	7.6475	51.7218
Difference $v3 = v1 - v2$	4995	0.0002	115.3166	4.4652	8.0815	180.9871
Nugget effect C_0	4995	4.1435	146.4984	14.7485	11.5229	78.1291

Tab. 8. Statistical parameters of the filtered values, i.e. components of semivariogram models of power in the 110 kV network, using ordinary kriging (wintertime, 11:00 hrs)

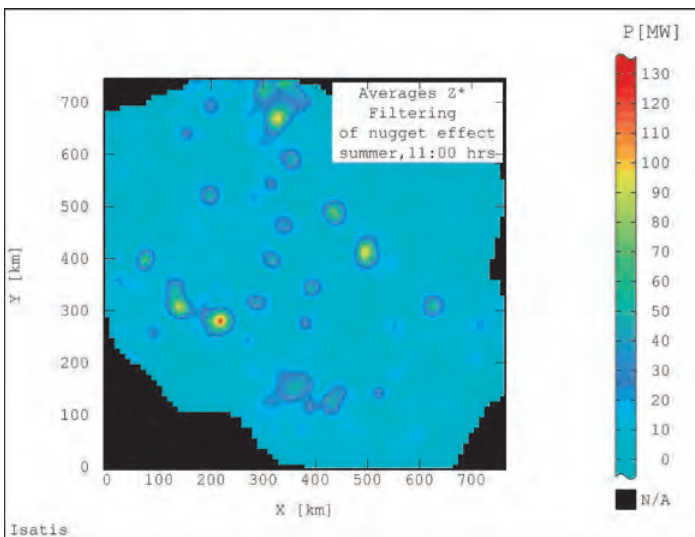


Fig. 15a. Raster map of the distribution of estimated average powers Z^* ; filtering of nugget effect C_0 – summertime, 11:00 hrs; ordinary point kriging, moving neighbourhood ($4 \times 8 \times 3$)

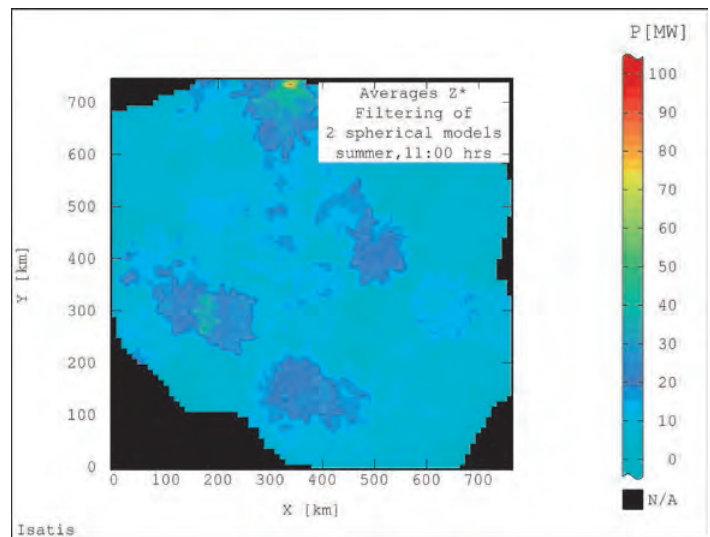


Fig. 15b. Raster map of the distribution of estimated average powers Z^* ; filtering of complex theoretical model components – summertime, 11:00 hrs; ordinary point kriging, moving neighbourhood ($4 \times 8 \times 3$)




Fig. 15c. Raster map of the distribution of differences between the estimated averages Z^* (v_1) and the averages Z^* corresponding to the complex theoretical model – summertime 11:00 hrs ($v_3 = v_1 - v_2$); ordinary point kriging, moving neighbourhood ($4 \times 8 \times 3$)

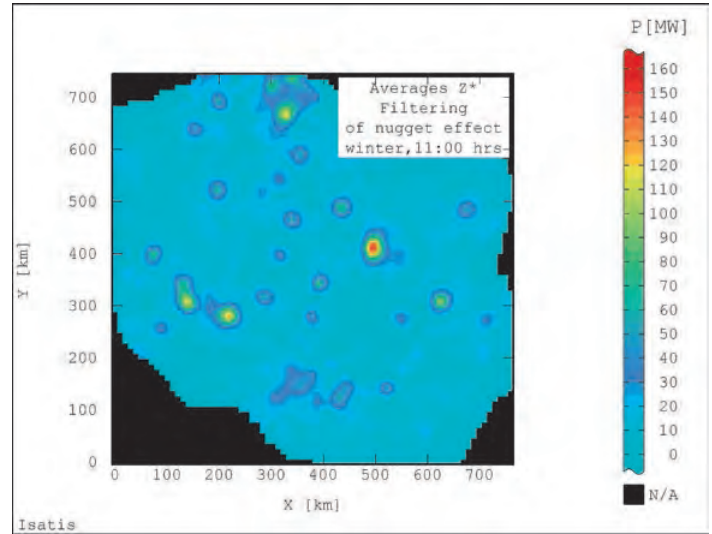


Fig. 16a. Raster map of the distribution of estimated average powers Z^* ; filtering of nugget effect C_0 – wintertime, 11:00 hrs; ordinary point kriging, moving neighbourhood ($4 \times 8 \times 3$)

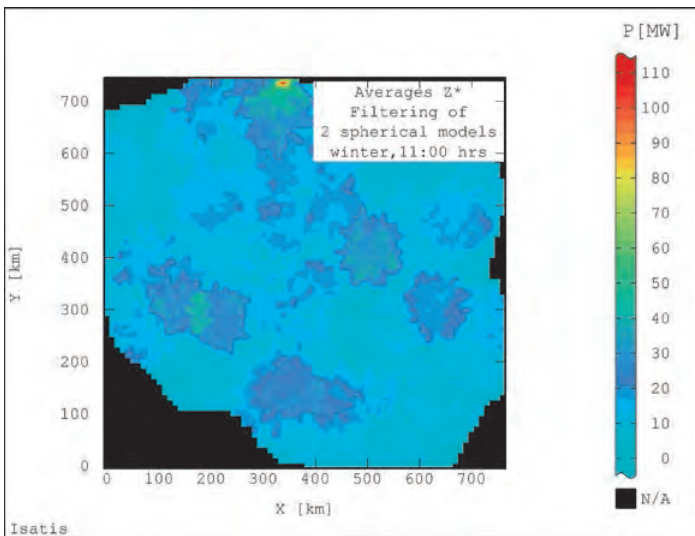


Fig. 16b. Raster map of the distribution of estimated average powers Z^* ; filtering of components (spherical functions) of complex theoretical model – wintertime, 11:00 hrs; ordinary point kriging, moving neighbourhood ($4 \times 8 \times 3$)

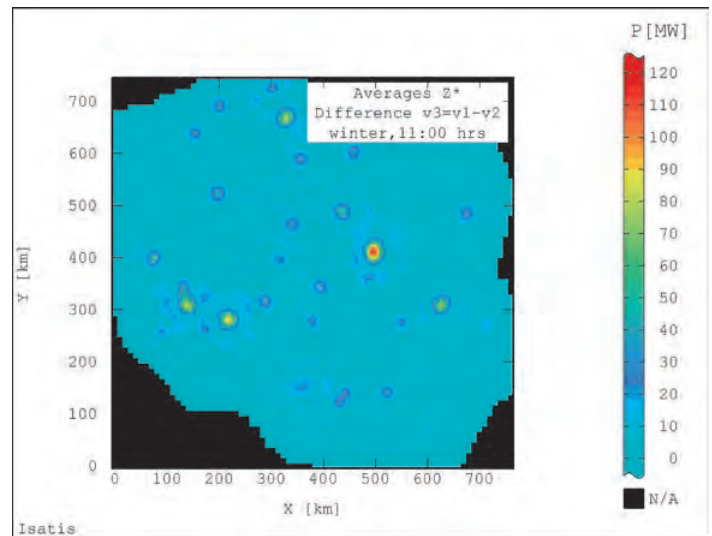


Fig. 16c. Raster map of the distribution of differences between the estimated averages Z^* (v_1) and the averages Z^* corresponding to the complex theoretical model – wintertime 11:00 hrs ($v_3 = v_1 - v_2$); ordinary point kriging, moving neighbourhood ($4 \times 8 \times 3$)




Fig. 17a. Scatter graph of the total averages Z^* and the averages Z^* after filtering nugget effect C_0 out – summertime, 11:00 hrs; ordinary point kriging




Fig. 17b. Scatter graph of the total averages Z^* and the averages Z^* after filtering out the 1st component of spherical model – summertime, 11:00 hrs; ordinary point kriging

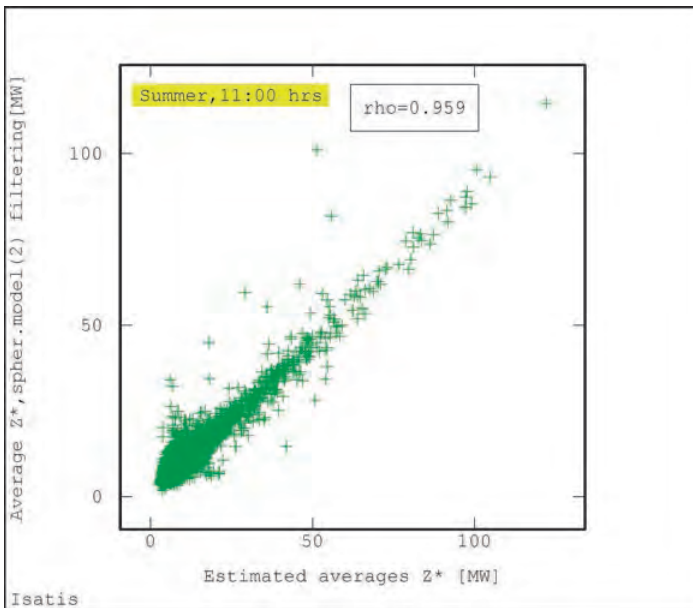


Fig. 17c. Scatter graph of the total averages Z^* and the averages Z^* after filtering out the 2nd component of spherical model – summertime, 11:00 hrs; ordinary point kriging




Fig. 18a. Scatter graph of the total averages Z^* and the averages Z^* after filtering nugget effect C_0 out – wintertime, 11:00 hrs; ordinary point kriging




Fig. 18b. Scatter graph of the total averages Z^* and the averages Z^* after filtering out the 1st component of spherical model – wintertime, 11:00 hrs; ordinary point kriging




Fig. 18c. Scatter graph of the total averages Z^* and the averages Z^* after filtering out the 2nd component of spherical model - wintertime, 11:00 hrs; ordinary point kriging

REFERENCES

- Namysłowska-Wilczyńska B., Wilczyński A., Filtrowanie składowych modeli wariogramów mocy elektrycznej w krajowej sieci 110 kV z zastosowaniem krigingu, [Filtering of components of variogram models of electrical power in the national 110 kV grid with the use of kriging] the VII th National Scientific Conference INFOBAZA 2014 Inspiration • Integration • Implementation, Gdańsk University of Technology, Institute of Oceanology of the Polish Academy of Sciences, TASK Academic Computer Centre in Gdańsk. Gdańsk – Sopot, 8–10 Sep. 2014, Conference proceedings, electronic version, full version of the paper, a national paper, abstract in Polish, pp. 43–44; Filtering the components in models of electrical power variograms for national 100 kV network using kriging estimation. Abstract in English, pp. 44–45.
- Namysłowska-Wilczyńska B., Studium modelowania i szacowania porfirowego złoża miedzi Rio Blanco w Peru. 3D modelling and estimating of Rio Blanco porphyritic copper deposit in Peru, *Prace Wrocławskiego Towarzystwa Naukowego B SERIES*, No. 220. KOPMUTEROWE WSPOMAGANIE BADAŃ NAUKOWYCH XXI [COMPUTER-AIDED SCIENTIFIC RESEARCH XXI], Wrocław 2014, pp. 53–65.
- Namysłowska-Wilczyńska B., Analizy przestrzenne z zastosowaniem metod geostatystycznych. Modelowanie 3D porfirowego złoża miedzi Rio Blanco w Peru [Spatial analyses with the use of geostatistical methods. 3D modelling of Rio Blanco porphyritic copper deposit in Peru, *ROZNIKI GEOMATYKI (Annals of Geomatics)* 2007, The Polish Association for Spatial Information, Warsaw, Vol. V, book 1, pp. 91–103.
- Namysłowska-Wilczyńska B., Geostatistical methods used to estimate Sieroszowice copper ore deposit parameter. *Zeitschrift für Geologische Wissenschaften, Journal for the Geological Sciences*, Berlin 2012, 40 (6), pp. 329–361.
- Namysłowska-Wilczyńska B., Uncertainty estimation through geostatistical simulations Geomin 2013 3rd International Seminar on Geology for the Mining Industry, 24–26 July 2013, Santiago, Chile. Proceedings GEOMIN 2013. Chapter 2 Modelling and Geostatistics. Gecamin Publications, Edit. Jozsef Ambrus et al., pp. 63–70.
- Namysłowska-Wilczyńska B., Skorupska B., Wieniewski A., Analiza geostatystyczna zmienności parametrów technologicznych popiołożużli zdeponowanych na składowisku odpadów przemysłowych [Geostatistical analysis of the variability of technological parameters of ash/shalg deposits in an industrial waste landfill], *Ochrona Środowiska* 2012, Vol. 34, No. 2, pp. 43–48.
- Namysłowska-Wilczyńska B., Wilczyński A., Analiza obciążeń sieci NN i 110 kV zamkniętej z wykorzystaniem optymalizacji geostatystycznej [Analysis of loads in LV and 110kV open grid with the use of geostatistical optimisation], Part I, Raport series SPR No. 13/2002, commissioned by PSE S.A., Institute of Geotechnics and Hydrotechnics of Wrocław University of Technology, Wrocław 2002.
- Namysłowska-Wilczyńska B., Wilczyński A., Funkcja wariogramu jako narzędzie badania zmienności obciążeń elektrycznych w układzie powierzchniowym [The variogram function as a tool for studying the spatial variation of electrical loads], *Elektroenergetyka* 2003, No. 4, pp. 18–34.
- Namysłowska-Wilczyńska B., Wilczyński A., Zastosowanie metod geostatystycznych do analizy przestrzennej zmienności obciążeń elektrycznych dla obszaru Polski [An application of geostatistical methods for spatial analysis of the electrical load variation in Poland,

- Roczniki Geomatyki* 2005, Vol. III, book 2, The Polish Association for Spatial Information, pp. 125–134.
10. Namysłowska-Wilczyńska B., Wilczyński A., Tymorek A., Modelowanie powierzchniowe obrazu zmian obciążeń elektrycznych z zastosowaniem kriginu lognormalnego [Spatial modelling of the image of changes in electrical loads with the use of lognormal using kriging], *Elektroenergetyka* 2004, No. 1, pp. 1–15.
 11. Namysłowska-Wilczyńska B., Wilczyński A., Spatial Electrical Loads Modelling Using the Geostatistical Methods, International CODATA Conference 2004 "The Information Society: New Horizons for Science", Berlin, Germany, 7–10 November 2004, s. 25. pdf paper, [online] <http://www.codata.org/04conf/paper/Namyslowska-Wilczynska-paper>.
 12. Wilczyński A., Modelowanie powierzchniowe obciążeń elektrycznych z wykorzystaniem kriginowej metody estymacyjnej [Spatial modelling of electrical loads with the use of kriging estimation method], *Archiwum Energetyki* 2004, No. 1–2, pp. 31–50.
 13. Namysłowska-Wilczyńska B., Wilczyński A., 3D Electric power demand forecasting as a tool for planning electrical power firm's activity by means of geostatistical methods, *Econometrics. Forecasting*, No. 28, Research Papers of Wrocław University of Economics, No. 91, Wrocław 2010, pp. 95–112.
 14. Namysłowska-Wilczyńska B., Wilczyński A., Structural analysis of variation of electricity transmission marginal costs, *Ekonometria. Econometrics* 2013, No. 1 (39), Research Papers of Wrocław University of Economics, pp. 71–84.
 15. Namysłowska-Wilczyńska B., Wilczyński A., Geostatistical model (2D) of the surface distribution of electricity transmission marginal costs, *Econometrics. Econometria. Econometrics* 2013, No. 1 (39), Research Papers of Wrocław University of Economics, pp. 85–84.
 16. Namysłowska-Wilczyńska B., Geostatistical hydrogeochemical 3D model for Kłodzko underground water intake area. Part I. Estimation of basic statistics on quality parameters of underground waters, *Studia Geotechnica et Mechanica* 2013, Vol. XXXV, No. 1, pp. 157–181.
 17. Armstrong M., *Basic Linear Geostatistics*, Springer, Berlin 1998.
 18. Namysłowska-Wilczyńska B., *Geostatystyka – Teoria i Zastosowania [Geostatistics – Theory and Applications]*, Publishing House of the Wrocław University of Technology, Wrocław, 2006.

Barbara Namysłowska-Wilczyńska

Wrocław University of Technology

e-mail: Barbara.Namyslowska-Wilczynska@pwr.edu.pl

Prof. Namysłowska deals with research problems related to modelling, estimation and forecasting of parameters of mineral resources, copper ore deposits in particular. Her works are associated with a variety of applications of statistical and geostatistical methods (applied/ spatial statistics), including simulation techniques (conditional and unconditional simulation), in issues relating to the geology of deposits, mining, environmental and engineering, environmental protection, in waste landfill research, climatology, enzymology, geodesy, as well as in the energy sector. Author of many articles and research studies devoted to spatial and spatio-temporal (3D) analyses, uncertainty estimation, and volatility risk analysis of selected parameters used in solving certain issues. Recent studies include the development of geostatistical (3D) hydrochemical models of variation of underground waters quality parameters for a water intake area and mains water. Deputy Head of Hydrological Processes Modelling Centre in Wrocław. Titular professor.

Artur Wilczyński

Wrocław University of Technology

e-mail: Artur.Wilczynski@pwr.edu.pl

Prof. Wilczyński deals with research problems related to the planning and operation of power systems. His research interests include, inter alia, modelling and prediction of electrical load processes, also in 2D and 3D, energy security, research of tariff system structures and their impact on electricity consumption, restructuring of the power sector and energy markets creation, integration of distributed generation with the power system, modelling of environmental pollution. Full professor at the Technical University of Wrocław.

This is a supporting translation of the original text published in this issue of "Acta Energetica" on pages 72–87. When referring to the article please refer to the original text.

PL

Geostatystyczny opis struktury powierzchniowej zmienności mocy elektrycznej w krajowej sieci 110 kV z wykorzystaniem rezultatów filtrowania składowych modeli wariogramów

Autorzy

Barbara Namysłowska-Wilczyńska
Artur Wilczyński

Słowa kluczowe

moc elektryczna, zmienność powierzchniowa, modelowanie geostatystyczne, kriging zwyczajny, kriging lognormalny, filtrowanie składowych modeli wariogramów

Streszczenie

W artykule przedstawiono rezultaty analizy powierzchniowej zmienności mocy elektrycznych z wykorzystaniem dwóch metod geostatystycznych – krigingu lognormalnego i krigingu prostego. Celem pracy było dokładne scharakteryzowanie i rozpoznanie struktury zmienności obciążeń elektrycznych w węzłach sieci 110 kV na obszarze całego kraju, analizowanej na podstawie uzyskanych rezultatów użycia technik krigingowych. W artykule zaproponowano metodologię wykorzystującą dwie techniki modelowania i szacowania wartości średnich Z^* mocy elektrycznych, tj. kriging lognormalny i kriging prosty.

Danymi wejściowymi do obliczeń były moce elektryczne w węzłach sieci 110 kV, związane z tym samym momentem czasowym, tj. godz. 11.00, w okresach letnim i zimowym.

Obliczenia krigingowe wykonano przy założeniu różnych wariantów badania. Przeprowadzono filtrowanie przyjętych złożonych modeli teoretycznych semiwariogramów mocy elektrycznych, czyli rozdzielanie modeli na różne składowe (efekt samorodków, 1 model sferyczny, 2 model sferyczny), które były kolejno odfiltrowywane. Następnie szacowano wartości średnich Z^* mocy, z pominięciem poszczególnych składowych.

Rezultaty analiz wykonanych z uwzględnieniem kolejnych składowych modeli semiwariogramów przedstawiono na mapach rastrowych rozkładów wartości średnich estymowanych Z^* mocy. Pozwoliło to na zorientowanie się w zmianach wartości tego parametru zarówno na obszarze całego kraju, jak i w czasie, w dwóch sezonach roku, letnim i zimowym, a także przy założeniu różnych składowych modeli semiwariogramów obciążeń. Dokładna analiza zmienności przestrzenno-czasowej średnich Z^* obciążeń elektrycznych, przeprowadzona dla obszaru kraju, umożliwiła zorientowanie się w ich zakresie i charakterze zróżnicowania.

1. Wstęp

W procesie planowania rozwoju i eksploatacji infrastruktury sieci elektroenergetycznych, adekwatnej do występującego zapotrzebowania na moc elektryczną w danym momencie czasowym i obszarze, zastosowanie znajduje powierzchniowe modelowanie rozkładu obciążeń elektrycznych, a w dalszej kolejności szacowanie i prognozowanie wartości tych obciążeń. Spełnienie warunku efektywności ekonomicznej i bezpieczeństwa pracy systemu elektroenergetycznego wymaga bowiem uzyskania odpowiedzi na pytania: w których miejscach obciążenia wzrastają, w jakim stopniu się zmieniają wraz z lokalizacją oraz jaki jest geograficzny kierunek tych zmian?

Modele przestrzenno-czasowego rozkładu zmienności poboru mocy, opracowane dla określonego obszaru i poszczególnych godzin doby, mogą również być wykorzystane w tzw. zarządzaniu energią, tj. kształtowaniu zarówno strony podaży (ang. *Supply Side Management* – SSM), jak też strony popytu (ang. *Demand Side Management* – DSM). Ma to szczególne znaczenie w sytuacji zwiększającego się udziału małych, w tym niekonwencjonalnych źródeł energii, których praca cechuje się dużym poziomem niepewności. W artykule¹ zastosowano metody geostatystyczne, już wcześniej wykorzystywane przez autorów do powierzchniowego modelowania i prognozowania zjawisk

rozwijających się w układach 2D i 3D, m.in. w takich obszarach jak: geologia i górnictwo [2, 3, 4, 5], badania stanu środowiska [6], energetyka [7–15], ekonomia [14, 15], czy też hydrogeologia [16].

Zasadniczym celem pracy było scharakteryzowanie i rozpoznanie struktury zmienności obciążeń elektrycznych na obszarze całego kraju, analizowanej na przykładzie danych dotyczących mocy w węzłach sieci

110 kV, w świetle uzyskanych rezultatów użycia funkcji wariogramu i technik krigingowych, z uwzględnieniem także wyników filtrowania poszczególnych składowych badanego procesu. Zaproponowano metodologię badawczą wykorzystującą dwie techniki geostatystyczne szacowania wartości średnich Z^* mocy elektrycznych, tj. kriging zwyczajny i kriging lognormalny, stosując różne sąsiedztwa wyszukiwania próbek


Analizowany parametr	Liczebność próbek N	Wartość X_{\min} [MW]	Wartość X_{\max} [MW]	Wartość średnia \bar{X} [MW]	Odchylenie standardowe S [MW]	Współczynnik zmienności V [%]
moc elektryczna (lato, godz. 11.00)	1123	0,10	277,54	16,02	31,34	195,58
moc elektryczna (zima, godz. 11.00)	1132	0,12	356,18	21,13	40,57	191,99

Tab. 1. Podstawowe parametry statystyczne mocy elektrycznych w sieci elektroenergetycznej 110 kV (na podstawie danych oryginalnych)


Analizowany parametr	Liczebność próbek N	Wartość X_{\min} [MW]	Wartość X_{\max} [MW]	Wartość średnia \bar{X} [MW]	Odchylenie standardowe S [MW]	Współczynnik zmienności V [%]
moc elektryczna (lato, godz. 11.00)	1022	-2,30	5,53	1,90	0,93	48,83
moc elektryczna (zima, godz. 11.00)	1029	-2,12	5,67	2,19	0,95	43,24

Tab. 2. Podstawowe parametry statystyczne mocy elektrycznych w sieci elektroenergetycznej 110 kV (dane zlogarytmowane)


¹ Fragmenty niniejszego artykułu zaprezentowano na VII Krajowej Konferencji Naukowej INFOBAZY 2014, Inspiracja • Integracja • Implementacja, zorganizowanej przez Politechnikę Gdańską, Instytut Oceanologii PAN i TASK Centrum Informatyczne, Gdańsk – Sopot, 8–10.09.2014 i opublikowano w referacie [1].




Rys. 1. Histogram rozkładu wartości oryginalnych mocy elektrycznych [MW] w węzłach sieci 110 kV – okres letni, godz. 11.00



Rys. 2. Histogram rozkładu wartości zlogarytmowanych (ln) mocy elektrycznych [MW] w węzłach sieci 110 kV – okres letni, godz. 11.00



Rys. 3. Histogram rozkładu wartości oryginalnych mocy elektrycznych [MW] w węzłach sieci 110 kV – okres zimowy, godz. 11.00



Rys. 4. Histogram rozkładu wartości zlogarytmowanych (ln) mocy elektrycznych [MW] w węzłach sieci 110 kV – okres zimowy, godz. 11.00

– ustalone i ruchome. W celu dokładniejszego rozpoznania badanego zjawiska przeprowadzono odfiltrowywanie różnych składowych procesu zmienności zapotrzebowania na moc (przedstawionych na modelach wariogramów i na mapach rastrowych), z użyciem krigingu zwyczajnego. Analizy przestrzenne zmienności wartości mocy elektrycznej wykonano z wykorzystaniem pakietu programów statystycznych ISATIS (wersja 2014.1), Firmy Geovariances, Avon-Cedex, France.

2. Podstawowe statystyki obciążeń elektrycznych w sieci elektroenergetycznej 110 kV

Przedmiotem badań było zróżnicowanie powierzchniowe i czasowe, analizowane na podstawie zbioru danych próbkowych, dotyczących pomiarów mocy elektrycznych w węzłach sieci 110 kV, obejmujących obszar całego kraju. Dane były związane z dwoma charakterystycznymi momentami czasowymi, mianowicie: z okresami letnim i zimowym, godz. 11.00. Ze względu na poufność danych nie podano roku, którego dotyczą. Zamiarem autorów było zaprezentowanie metodyki badawczej szacowania wartości średnich mocy elektrycznej, wykorzystującej narzędzia geostatystyki. W badaniach wykorzystano zawartości baz danych zawierających wartości współrzędnych X i Y lokalizacji węzłów sieciowych

(punktów pomiarowych) oraz mocy elektrycznych P , występujących w tych węzłach. Liczebności punktów pomiarowych n wynosiły odpowiednio – 1123 (dla lata) i 1132 (dla zimy) [7]. We wstępnym etapie analiz przedmiot oceny stanowiły podstawowe parametry statystyczne dla szczytu rannego w okresach: letnim i zimowym (tab. 1), wyznaczone na podstawie danych oryginalnych. Z uwagi na dużą dodatnią skośność badanego procesu obliczenia podstawowych statystyk przeprowadzono na podstawie danych zlogarytmowanych (ln) (tab. 2). Wartości minimalne, maksymalne i średnie mocy elektrycznych są wyraźnie wyższe w przypadku okresu zimowego (tab. 1). Natomiast wartości współczynników zmienności V mocy dla całego kraju są zbliżone dla obu okresów i wskazują na ekstremalnie dużą zmienność wartości mocy. Po dokonaniu przekształcenia wartości oryginalnych na wartości zlogarytmowane zauważa się, że opisywana wyżej prawidłowość poziomu wartości podstawowych statystyk (min., max i średnie) mocy utrzymuje się, osiągając większe wartości dla okresu zimowego (tab. 2). Natomiast wartości standardowego odchylenia są prawie identyczne. Wartości współczynników V różnią się nieistotnie dla obu okresów, jednakże trochę większą wartość współczynnika V uzyskano dla okresu letniego.

3. Histogramy rozkładów obciążeń elektrycznych w sieci elektroenergetycznej 110 kV


Obliczenie histogramów rozkładów mocy elektrycznych stanowiło kolejny etap analiz (rys. 1–4). Histogramy rozkładów mocy elektrycznych, sporządzone na podstawie danych oryginalnych, są asymetryczne (jednoskrzydłowe), z dominującymi klasami modalnymi, co potwierdzają duże wartości współczynników skośności dodatniej g_1 : 4,43 (lato) – 4,67 (zima) (rys. 1, 3). O smukłości rozkładów świadczą wartości współczynników kurtozy g_2 : 25,85 (lato) – 29,10 (zima). Natomiast histogramy rozkładów wartości zlogarytmowanych (ln) wykazują podobieństwo do rozkładu Gaussa dla obu analizowanych okresów (rys. 2, 4), przy czym wartości współczynnika skośności g_1 zawierają się w granicach od 0,33–0,085, natomiast współczynnika kurtozy g_2 od: 5,68–5,95.

4. Metodyka modelowania rozkładu powierzchniowego obciążeń elektrycznych


Dla oszacowania zmienności powierzchniowej mocy w węzłach sieci 110 kV wykorzystano metody geostatystyczne, jak: funkcja wariogramu oraz dwie techniki estymacyjne – krigingu zwyczajnego i krigingu lognormalnego (w modyfikacji blokowej i punktowej). Obliczenia krigingowe wykonano z uwzględnieniem ustalonego i ruchomego „sąsiedztwa” (podobszaru wyszukiwania próbek), w różnych wariantach analiz. Przeprowadzono proces filtrowania struktury zmienności mocy scharakteryzowanej za pomocą złożonych modeli teoretycznych, opisujących przebiegi semiwariogramów mocy elektrycznych. Proces ten polega na rozdzieleniu przyjętych modeli na różne składowe (np. efekt samorodków, 1 model sferyczny, 2 model sferyczny), które są kolejno odfiltrowywane. Oznacza to, że wartości średnich estymowanych Z^* mocy będą szacowane w kolejnych krokach. W praktyce model sferyczny jest jednym z najczęściej stosowanych modeli do aproksymacji przebiegów semiwariogramów empirycznych w przestrzeni Euklidesa, o wymiarach nie większych niż 3 [18].

W pracy sukcesywnie dokonano odfiltrowania poszczególnych składowych przyjętych modeli teoretycznych semiwariogramów. Obliczono też różnice pomiędzy średnimi Z^* reprezentującymi poszczególne składowe zmienności mocy elektrycznych. Ponadto wyznaczono efekt samorodków C_0 , stanowiący składnik losowy procesu zmienności.

Efekt samorodków C_0 jest to widoczna nieciągłość w przebiegu semiwariogramu empirycznego (w punkcie wyjściowym wykresu $\gamma(h)$ [18]). Efekt ten jest spowodowany błędami pomiarów lub strukturami mikrogniazdowymi, mniejszymi niż dystansy próbowania, lub obydwoma przyczynami. W początku wykresu semiwariogramu wartość funkcji $\gamma(h)$ wynosi zawsze 0, jednakże w razie obecności efektu C_0 dąży ona do wartości dodatniej C_0 , istotnie większej niż 0. Obecność efektu C_0 świadczy o występowaniu lokalnej zmienności, co oznacza gwałtowne wahania wartości mocy elektrycznej.



Rys. 5. Semiwariogram wartości oryginalnych mocy elektrycznych [MW] w węzłach sieci 110 kV, aproksymowany modelem teoretycznym – okres letni, godz. 11.00



Rys. 6. Semiwariogram wartości oryginalnych mocy elektrycznych [MW] w węzłach sieci 110 kV, aproksymowany modelem teoretycznym – okres zimowy, godz. 11.00

Analizowany okres	Efekt samorodków C_0 [MW] ²	Częstkowa wariancja C' [MW] ²	Całkowita wariancja progowa C [MW] ²	Zasięg oddziaływania a [km]	Typ modelu
Lato godz. 11.00	259,1096	246,9215 27,0395	533,0705	39 39	efekt samorodków 1 model sferyczny 2 model sferyczny
Zima godz. 11.00	400,7893	376,1724 54,6925	831,6541	34 81	efekt samorodków 1 model sferyczny 2 model sferyczny

Tab. 3. Zestawienie wartości parametrów geostatystycznych modeli semiwariogramów obciążeń w węzłach sieci 110 kV (obliczenia na podstawie danych oryginalnych)

Analizowany okres	Efekt samorodków C_0 [MW] ²	Częstkowa wariancja progowa C' [MW] ²	Całkowita wariancja progowa C [MW] ²	Zasięg oddziaływania a [km]	Typ modelu
Lato godz. 11.00	0,6104	0,1949 0,0824	0,8877	33 70	efekt samorodków 1 model sferyczny 2 model sferyczny
Zima godz. 11.00	0,6482	0,2753	0,9235	32	efekt samorodków sferyczny

Tab. 4. Zestawienie wartości parametrów geostatystycznych modeli semiwariogramów obciążeń w węzłach sieci 110 kV (obliczenia na podstawie danych zlogarytmowanych ln)

4.1. Funkcja wariogramu

Wariogram (semiwariogram) empiryczny, opisujący skorelowanie badanych zmiennych – mocy elektrycznych, rozmieszczonych na powierzchni (w układzie 2D), jest przedstawiony następującą zależnością [8, 17, 18]:

$$\gamma^*(h) = \frac{1}{2n_h} \cdot \sum_{i=1}^{n_h} [z(x_i + h) - z(x_i)]^2 \quad (1)$$

gdzie:

$z(x_i + h)$, $z(x_i)$ – wartości mocy elektrycznych w punktach x_i i $x_i + h$, a więc oddalonych o odległość h ; n_h – liczba par $(x_i, x_i + h)$ wartości mocy w punktach oddalonych o dystans h , wykorzystywanych w obliczaniu funkcji semiwariogramu $\gamma^*(h)$. Przebiegi wariogramów empirycznych opisują charakter i stopień zmienności rozważanej zmiennej zregionalizowanej, czyli mocy elektrycznych w węzłach 110 kV.

4.2. Technika kriginu zwyczajnego

W procesie estymacji został użyty krigin zwyczajny, który stosuje się do oszacowania wartości średniej Z^* w lokalizacji punktowej (krigin zwyczajny – punktowy) lub w centrum bloku (krigin zwyczajny – blokowy) [10, 17, 18]. Technika ta pozwala szacować średnią wartość punktową lub blokową w węzłach elementarnej siatki prostokątnej lub kwadratowej (centrum bloku) jako średnią ważoną Z^* , obliczoną na podstawie wartości pomiarów pochodzących z lokalnego sąsiedztwa, czyli z obszaru przeszukiwania próbek, dla środka elipsy lub okręgu, umieszczonych w węzle bądź w obrębie bloku. Jednocześnie wraz z każdą średnią wartością estymowaną Z^* (oceną kriginową) obliczane jest standardowe odchylenie estymacji (kriginowe) σ_k bądź wariancja kriginu σ_k^2 .

Estymacji średniej ważonej (ruchomej) Z^* dokonuje się na podstawie następującej zależności:

$$Z_k^* = \sum_{i=1}^n w_{ik} z_i \quad (2)$$


gdzie:

z_i – wartość analizowanego parametru, tj. mocy elektrycznej, w punkcie i , dla $i = 1, \dots, n$; współczynnik wagowy (waga) kriginu, przypisany próbce i . Dysponując tzw. kriginowym systemem równań (estymacji) [6], możliwe staje się wyznaczenie współczynników wag w_{ik} , przypisanych danym próbkowym w obrębie szacowanego obszaru i w jego pobliżu. Pozwalają one następnie obliczyć precyzyjny błąd, zwany błędem kriginu, którego wariancję określa wzór:


$$\sigma_k^2 = \sum w_{ik} \bar{\gamma}(S_i, A) + \lambda - \bar{\gamma}(A, A) \quad (3)$$

gdzie:

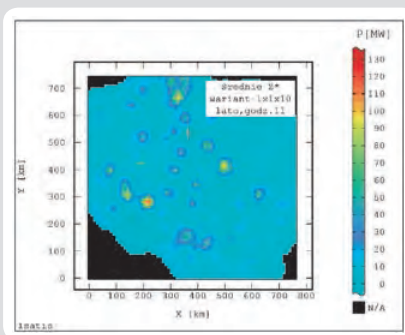
w_{ik} – współczynnik wagowy (waga) kriginu, przypisany próbce i ; $\bar{\gamma}(A, A)$ – wartość średnia funkcji wariogramu między każdymi dwoma punktami w bloku A ; $\bar{\gamma}(S_i, A)$ – wartość średnia funkcji wariogramu między wartościami próbkowymi S_i i punktami w bloku A , λ – mnożnik Lagrange'a.



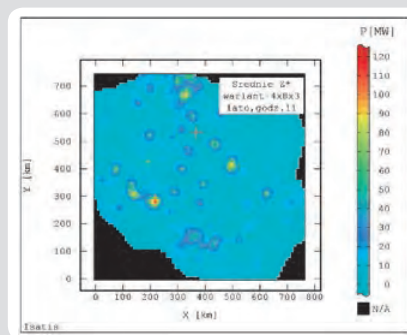
Rys. 7. Semiwariogram wartości zlogarytmowanych mocy elektrycznych [MW] w węzłach sieci 110 kV, aproksymowany modelem teoretycznym – okres letni, godz. 11.00



Rys. 8. Semiwariogram wartości zlogarytmowanych mocy elektrycznych [MW] w węzłach sieci 110 kV, aproksymowany modelem teoretycznym – okres zimowy, godz. 11.00



Rys. 9a. Mapa rastrowa rozkładu średnich estymowanych Z^* mocy elektrycznych – okres letni, godz. 11.00; kriging zwyczajny blokowy (sąsiedztwo ruchome wyszukiwania próbek – $1 \times 1 \times 10$)



Rys. 9b. Mapa rastrowa rozkładu średnich estymowanych Z^* mocy elektrycznych – okres letni, godz. 11.00; kriging zwyczajny blokowy (sąsiedztwo ruchome wyszukiwania próbek – $4 \times 8 \times 3$)

Wartość wariancji krigingu σ_k^2 zależy od położenia próbek względem lokalizacji, która ma być szacowana, i od parametrów przyjętego modelu teoretycznego wariogramu empirycznego.

4.3. Technika krigingu lognormalnego
Kriging lognormalny (ang. *lognormal kriging* – LK), określane też jako logarytmiczny, stosuje się do szacowania wartości średnich na podstawie danych charakteryzujących się dużą skośnością, o rozkładzie

lognormalnym, np. trójparametrycznym (logarytmy danych plus stała) [10]. Dane oryginalne, przekształcone na logarytmy naturalne $\ln[Z]$ mają rozkład normalny. Kriging lognormalny jest popularny w badaniach geostatystycznych, w sytuacji, gdy występują w subpopulacji próbkowej wysokie, odbiegające wartości danych. Jeśli jedna z nich pojawia się w małym zbiorze danych, powoduje to efekt dysproporcjonalny. Użycie tej techniki krigingu do szacowania danych lognormalnych daje niższe wartości wariancji krigingu w porównaniu z krigingiem prostym. Zwykle obserwuje się obciążenie (niedoszacowanie) wyników obliczeń, rzędu 5–7% [18].

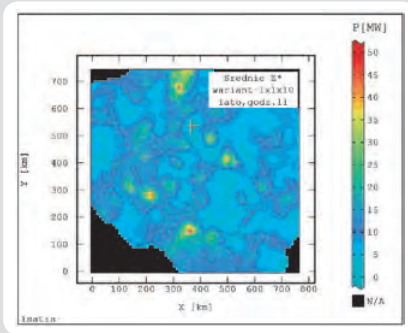
5. Modelowanie wariogramów mocy elektrycznych

W tab. 3–4 zestawiono wartości parametrów geostatystycznych i rodzaje modeli teoretycznych użytych do aproksymacji przebiegów wariogramów empirycznych, obliczonych z uwzględnieniem wartości oryginalnych (rys. 5–6) i zlogarytmowanych (\ln) (rys. 7–8) wartości mocy. Charakterystyczną cechą przebiegów wykresów funkcji semiwariogramu $\gamma(h)$ – obliczonych na podstawie danych (\ln) i aproksymowanych funkcjami teoretycznymi – jest ich bardzo dobra zgodność (rys. 7–8), znacznie lepsza niż w przypadku semiwariogramów obliczonych z wykorzystaniem danych oryginalnych (rys. 5–6). Na ogół do aproksymacji przyjęto model złożony z jednej lub dwóch funkcji – sferycznej oraz efektu samorodków. Dotyczy to zarówno danych pomiarowych dla okresów: letniego, jak i zimowego. Efekt samorodków C_0 i wariancja progowa C osiągają większe wartości dla okresu zimowego, natomiast zasięgi oddziaływania (krótkoskalowe zmiany) na semiwariogramach są porównywalne dla analizowanych okresów (tab. 3–4). Pojęcie efektu samorodków C_0 omówiono w rozdziale 4. Efekt C_0 i wariancja cząstkowa C' dają w sumie całkowitą wariancję progową C , która przedstawia ogólną zmienność badanej wielkości, tj. mocy elektrycznej.

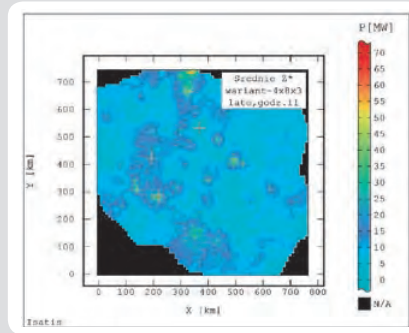
Wariancja progowa C stanowi górną granicę dla przyjętego modelu wariogramu, możliwą do osiągnięcia na znacznych odległościach, dla dużych argumentów przechodniego typu wariogramu [18]. Zasięg oddziaływania wariogramu a dla modelu sferycznego jest to odległość, przy której model osiąga wartość maksymalną – wariancję progową C (próg). Zasięg a oznacza, że do tej odległości występuje mierzalna korelacja z sąsiednimi wartościami próbkowymi.

6. Powierzchniowe rozkłady mocy elektrycznych z zastosowaniem technik krigingowych


Obliczenia z wykorzystaniem krigingu zwyczajnego i lognormalnego przeprowadzono w różnych wariantach sąsiedztwa, tj. z przyjęciem następujących parametrów dotyczących obszaru wyszukiwania próbek, tj. $1 \times 1 \times 10$, $4 \times 8 \times 3$, a ponadto sąsiedztwa ustalonego. W tym ostatnim przypadku oznacza to, że wszystkie dane dotyczące analizowanego obszaru były uwzględniane podczas szacowania średnich estymowanych Z^* w poszczególnych węzłach siatki elementarnej (tab. 5 i 6).



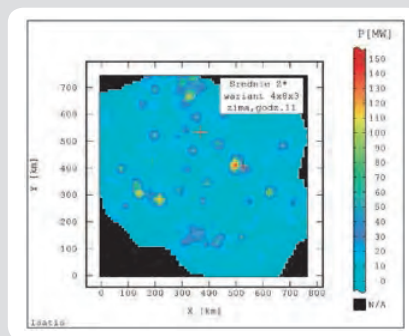
Rys. 10a. Mapa rastrowa rozkładu średnich estymowanych Z^* mocy elektrycznych – okres letni, godz. 11.00; kriging lognormalny blokowy (sąsiedztwo ruchome wyszukiwania próbek – $1 \times 1 \times 10$)



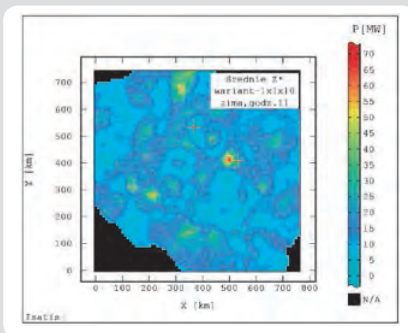
Rys. 10b. Mapa rastrowa rozkładu średnich estymowanych Z^* mocy elektrycznych – okres letni, godz. 11.00; kriging lognormalny blokowy (sąsiedztwo ruchome wyszukiwania próbek – $4 \times 8 \times 3$)



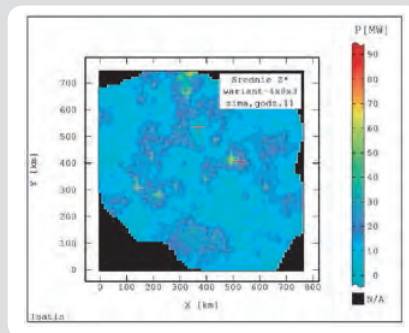
Rys. 11a. Mapa rastrowa rozkładu średnich estymowanych Z^* mocy elektrycznych – okres zimowy, godz. 11.00; kriging zwyczajny blokowy (sąsiedztwo ruchome wyszukiwania próbek – $1 \times 1 \times 10$)



Rys. 11b. Mapa rastrowa rozkładu średnich estymowanych Z^* mocy elektrycznych – okres zimowy, godz. 11.00; kriging zwyczajny blokowy (sąsiedztwo ruchome wyszukiwania próbek – $4 \times 8 \times 3$)



Rys. 12a. Mapa rastrowa rozkładu średnich estymowanych Z^* mocy elektrycznych – okres zimowy, godz. 11.00; kriging lognormalny blokowy (sąsiedztwo ruchome wyszukiwania próbek – $1 \times 1 \times 10$)



Rys. 12b. Mapa rastrowa rozkładu średnich estymowanych Z^* mocy elektrycznych – okres zimowy, godz. 11.00; kriging lognormalny blokowy (sąsiedztwo ruchome wyszukiwania próbek – $4 \times 8 \times 3$)

Dla okresu letniego uzyskano porównywalne maksymalne wartości średnich estymowanych Z^* dla dwóch rodzajów sąsiedztw: ruchomego $1 \times 1 \times 10$ i $4 \times 8 \times 3$. Wartości te były nieco mniejsze dla sąsiedztwa ustalonego (tab. 5).

Również wartości średnie obliczone na podstawie średnich estymowanych Z^* różniły się nieistotnie dla dwóch wariantów sąsiedztwa (ruchome: $1 \times 1 \times 10$ i $4 \times 8 \times 3$), natomiast dla sąsiedztwa ustalonego wartość ta była trochę większa. Duże wartości współczynnika zmienności V świadczą o dużej zmienności mocy dla okresu letniego, przy czym najmniejsze wartości V otrzymano

dla sąsiedztwa ustalonego dla okresów – letniego i zimowego.

W odniesieniu do okresu zimowego największa wartość maksymalna Z^* jest związana z przyjęciem sąsiedztwa ruchomego $1 \times 1 \times 10$, zaś najmniejsza wartość Z^* – z uwzględnieniem sąsiedztwa ustalonego. Odwrotnie sytuacja się przedstawia w przypadku wartości minimalnych (tab. 5), chociaż dla stosowanych wariantów analiz różnice pomiędzy nimi są niewielkie. Wyraźnie mniejsze wartości współczynnika zmienności V uzyskiwano w warunkach sąsiedztwa ustalonego. W warunkach przyjęcia sąsiedztwa ruchomego $1 \times 1 \times 10$

uzyskana wartość współczynnika V wskazywała na dużą zmienność mocy elektrycznej. Obliczenia związane z użyciem krigingu lognormalnego przeprowadzono, uwzględniając sąsiedztwo ruchome, w wymienionych wyżej dwóch wariantach obszaru przeszukiwania próbek (tab. 6). Minimalne wartości Z^* nie odbiegają zbytnio od uzyskanych metodą krigingu zwyczajnego, natomiast wartości maksymalne Z^* są znacznie niższe zarówno w odniesieniu do okresów: letniego, jak i zimowego. Może to świadczyć o tym, że metoda krigingu zwyczajnego lepiej odzwierciedla rzeczywisty charakter zmienności procesu obciążeń elektrycznych na obszarze całego kraju (tab. 5). Największe wartości maksymalne Z^* otrzymano dla sąsiedztwa ruchomego $4 \times 8 \times 3$, co dotyczy okresów: letniego i zimowego. Największe wartości współczynnika zmienności V uzyskiwano w warunkach sąsiedztwa ruchomego $1 \times 1 \times 10$, dla obu rozważanych okresów roku.

Rezultaty szacowania wartości średnich Z^* , przeprowadzonego z użyciem dwóch technik estymacyjnych, z uwzględnieniem sąsiedztwa ruchomego ($1 \times 1 \times 10$, $4 \times 8 \times 3$) pokazano na mapach rastrowych, dla krigingu zwyczajnego (rys. 9a, 9b) i krigingu lognormalnego (rys. 10a, 10b).

Porównując obrazy powierzchniowej zmienności poboru mocy elektrycznych dla okresu letniego (godz. 11.00), otrzymane z wykorzystaniem technik: krigingu zwyczajnego (rys. 9a i 9b) i lognormalnego (rys. 10a i 10b), można zauważyć, że zastosowanie tej pierwszej techniki lepiej odzwierciedla charakter zmian badanego procesu. W tym przypadku obrazy rastrowe bardziej szczegółowo odzwierciedlają zróżnicowanie wartości estymowanych mocy Z^* . Jednocześnie można stwierdzić, że użycie ruchomego sąsiedztwa wyszukiwania próbek daje dokładniejsze rezultaty (rys. 9a, 9b).

Podobne spostrzeżenia można poczynić na podstawie obrazów map rastrowych mocy dla okresu zimowego, sporządzonych z wykorzystaniem obu technik (rys. 11a, 11b, 12a i 12b). Zastosowanie krigingu zwyczajnego także daje dokładniejszy obraz zmian badanego procesu, z tym że oba użyte sąsiedztwa wyszukiwania próbek – $1 \times 1 \times 10$ oraz $4 \times 8 \times 3$ dają bardzo zbliżone wyniki (rys. 11a, 11b).

Szacowanie wartości średnich Z^* z wykorzystaniem krigingu zwyczajnego przeprowadzono dla trzech wariantów analiz, a zatem w obliczeniach zostały uwzględnione różne liczby węzłów siatki elementarnej, pokrywającej rozpatrywany obszar Polski. Wynika to z przyjętej procedury wyszukiwania próbek do wyznaczenia średnich estymowanych Z^* dla poszczególnych węzłów siatki. W przypadku stosowania sąsiedztwa ustalonego uwzględniono wszystkie próbki podczas estymacji poszczególnych węzłów ($N = 5775$), zaś sąsiedztwa ruchomego ($N = 4995$, wariant $4 \times 8 \times 3$), tj. maksymalnie – 32 próbki, minimalnie – 12 próbek, natomiast sąsiedztwa ruchomego ($N = 5224$, wariant $1 \times 1 \times 10$), tj. maksymalnie – 10 próbek i minimalnie – 1 próbka. Zatem dla niektórych węzłów siatki brakowało próbek do przeprowadzenia estymacji wartości średnich Z^* i dlatego dla nich średnie Z^* nie zostały obliczone.

Analizowany parametr	Liczba węzłów siatki N	Wartość X_{\min} [MW]	Wartość X_{\max} [MW]	Wartość średnia \bar{X} [MW]	Odchylenie standardowe S [MW]	Współczynnik zmienności V [%]
lato, godz. 11.00						
Sąsiedztwo ruchome $1 \times 1 \times 10$	4995	2,68 (6,97) *	122,11 (21,48)	11,14 (12,99)	10,33 (2,82)	92,70 (21,73)
Sąsiedztwo ruchome $4 \times 8 \times 3$	4995	2,81 (6,91)	117,29 (21,48)	11,11 (12,83)	9,60 (2,88)	86,36 (22,46)
Sąsiedztwo ustalone	4995	0,37 (6,87)	112,19 (14,85)	11,68 (11,99)	8,03 (1,91)	68,73 (15,89)
zima, godz. 11.00						
Sąsiedztwo ruchome $1 \times 1 \times 10$	4995	4,03 (8,79)	156,44 (26,58)	14,81 (16,26)	12,68 (3,38)	85,61 (20,82)
Sąsiedztwo ruchome $4 \times 8 \times 3$	4995	4,14 (8,71)	146,50 (26,58)	14,75 (16,02)	11,52 (3,47)	78,13 (21,67)
Sąsiedztwo ustalone	4995	4,21 (8,67)	143,09 (18,53)	15,37 (15,08)	9,80 (2,33)	63,77 (15,47)

*w nawiasach podano wartości standardowego odchylenia estymacji σ_k .

Tab. 5. Globalna statystyka wartości estymowanych Z^* mocy elektrycznych w sieci elektroenergetycznej 110 kV; kriging zwyczajny

Analizowany parametr	Liczba węzłów siatki N	Wartość X_{\min} [MW]	Wartość X_{\max} [MW]	Wartość średnia \bar{X} [MW]	Odchylenie standardowe S [MW]	Współczynnik zmienności V [%]
lato, godz. 11.00						
Sąsiedztwo ruchome $1 \times 1 \times 10$	5224	2,70 (0,32) *	49,49 (1,28)	10,16 (0,51)	4,83 (0,14)	47,51 (27,05)
Sąsiedztwo ruchome $4 \times 8 \times 3$	4995	3,63 (0,31)*	66,23 (0,79)	10,28 (0,47)	4,21 (0,09)	41,02 (18,20)
Sąsiedztwo ustalone	4995	3,63 (0,31)	66,14 (0,79)	10,28 (0,47)	4,21 (0,09)	40,98 (18,20)
zima, godz. 11.00						
Sąsiedztwo ruchome $1 \times 1 \times 10$	4995	4,03 (0,34)	68,53 (0,77)	14,21 (0,51)	6,25 (0,06)	44,00 (12,82)
Sąsiedztwo ruchome $4 \times 8 \times 3$	4995	4,84 (0,32)	86,09 (0,77)	14,06 (0,49)	5,17 (0,08)	36,76 (15,68)
Sąsiedztwo ustalone	4995	5,70 (0,32)	43,29 (0,48)	14,21 (0,44)	2,86 (0,03)	20,11 (7,42)

*w nawiasach podano wartości standardowego odchylenia estymacji σ_k .


Tab. 6. Globalna statystyka wartości estymowanych mocy elektrycznych w sieci elektroenergetycznej 110 kV; kriging lognormalny

Filtrowany parametr	Liczba węzłów siatki N	Wartość X_{\min} [MW]	Wartość X_{\max} [MW]	Wartość średnia \bar{X} [MW]	Odchylenie standardowe S [MW]	Współczynnik zmienności V [%]
Całkowita średnia estymowana Z^* (v1)	4995	2,6856	122,1101	11,1403	10,3270	92,70
Średnia Z^* dla modelu złożonego (1 sferyczny + 2 sferyczny) (v2)	4995	3,3480	91,5816	11,1389	6,4261	57,69
Różnica $v3 = v1 - v2$	4995	0,0000	97,8747	4,6040	7,5227	163,39
Efekt samorodków C_0	4995	2,8130	117,2879	11,1107	9,5952	86,36


Tab. 7. Parametry statystyczne wielkości filtrowanych, tj. składowych modeli semiwariogramów mocy elektrycznych w sieci elektroenergetycznej 110 kV, z zastosowaniem krigingu zwyczajnego (lato, godz. 11.00)

Filtrowany parametr	Liczba węzłów siatki N	Wartość X_{\min} [MW]	Wartość X_{\max} [MW]	Wartość średnia \bar{X} [MW]	Odchylenie standardowe S [MW]	Współczynnik zmienności V [%]
Całkowita średnia estymowana Z^* (v1)	4995	4,1435	146,4984	14,7485	11,5229	78,1291
Średnia Z^* dla modelu złożonego (1 sferyczny + 2 sferyczny) (v2)	4995	4,1418	106,7878	14,7857	7,6475	51,7218
Różnica $v3 = v1 - v2$	4995	0,0002	115,3166	4,4652	8,0815	180,9871
Efekt samorodków C_0	4995	4,1435	146,4984	14,7485	11,5229	78,1291


Tab. 8. Parametry statystyczne wielkości filtrowanych, tj. składowych modeli semiwariogramów mocy elektrycznych w sieci elektroenergetycznej 110 kV, z zastosowaniem krigingu zwyczajnego (zima, godz. 11.00)




Rys. 13a. Histogram rozkładu średnich estymowanych Z^* mocy elektrycznych [MW] w węzłach sieci 110 kV – okres letni, godz. 11.00; kriging zwyczajny, liczba węzłów siatki elementarnej $N = 4995$, sąsiedztwo ruchome wyszukiwania próbek $4 \times 8 \times 3$ ($X_{\min} = 3$, $X_{\max} = 117$, $\bar{X} = 11$, $S = 10$)




Rys. 13b. Histogram rozkładu średnich estymowanych Z^* mocy elektrycznych [MW] w węzłach sieci 110 kV – okres letni, godz. 11.00; kriging zwyczajny, liczba węzłów siatki elementarnej $N = 5224$, sąsiedztwo ruchome wyszukiwania próbek $1 \times 1 \times 10$ ($X_{\min} = 3$, $X_{\max} = 122$, $\bar{X} = 11$, $S = 10$)




Rys. 13c. Histogram rozkładu średnich estymowanych Z^* mocy elektrycznych [MW] w węzłach sieci 110 kV – okres letni, godz. 11.00; kriging zwyczajny, liczba węzłów siatki elementarnej $N = 5775$, sąsiedztwo ustalone ($X_{\min} = 0$, $X_{\max} = 112$, $\bar{X} = 12$, $S = 7$)



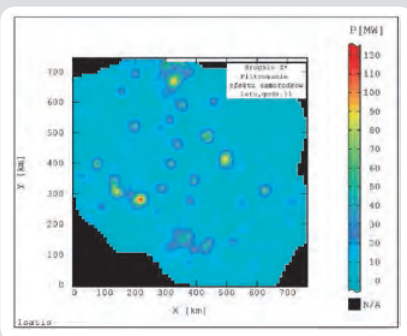
Rys. 14a. Histogram rozkładu średnich estymowanych Z^* mocy elektrycznych [MW] w węzłach sieci 110 kV – okres zimowy, godz. 11.00; kriging zwyczajny, liczba węzłów siatki elementarnej $N = 4995$, sąsiedztwo ruchome wyszukiwania próbek $4 \times 8 \times 3$ ($X_{\min} = 4$, $X_{\max} = 146$, $\bar{X} = 15$, $S = 12$)



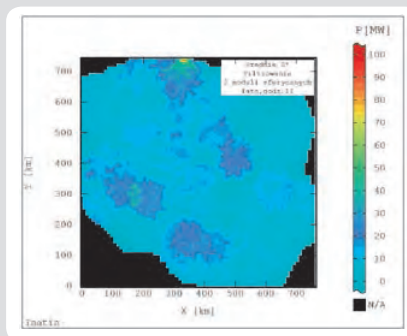
Rys. 14b. Histogram rozkładu średnich estymowanych Z^* mocy elektrycznych [MW] w węzłach sieci 110 kV – okres zimowy, godz. 11.00; kriging zwyczajny, liczba węzłów siatki elementarnej $N = 5224$, sąsiedztwo ruchome wyszukiwania próbek $1 \times 1 \times 10$ ($X_{\min} = 3$, $X_{\max} = 156$, $\bar{X} = 14$, $S = 13$)




Rys. 14c. Histogram mocy średnich estymowanych Z^* w węzłach sieci 110 kV – okres zimowy, godz. 11.00; kriging zwyczajny, liczba węzłów siatki elementarnej $N = 5775$, sąsiedztwo ustalone ($X_{\min} = 4$, $X_{\max} = 143$, $\bar{X} = 15$, $S = 9$)



Rys. 15a. Mapa rastrowa rozkładu średnich estymowanych Z^* mocy elektrycznych; filtrowanie efektu samorodków C_0 – lato, godz. 11.00; kriging zwyczajny punktowy, sąsiedztwo ruchome ($4 \times 8 \times 3$)



Rys. 15b. Mapa rastrowa rozkładu średnich estymowanych Z^* mocy elektrycznych; filtrowanie składowych złożonego modelu teoretycznego – lato, godz. 11.00; kriging zwyczajny punktowy, sąsiedztwo ruchome ($4 \times 8 \times 3$)



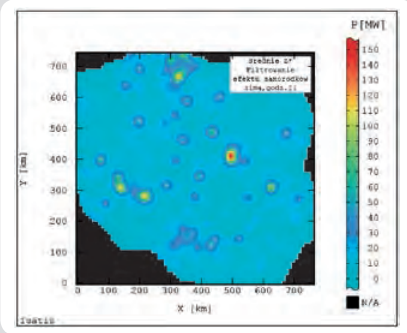
Rys. 15c. Mapa rastrowa rozkładu wartości różnic średnich estymowanych $Z^*(v1)$ i średnich Z^* odpowiadających złożonemu modelowi teoretycznemu – lato, godz. 11.00 ($v3 = v1 - v2$); kriging zwyczajny punktowy, sąsiedztwo ruchome ($4 \times 8 \times 3$)

Kształty histogramów rozkładów wartości średnich estymowanych Z^* , analizowane dla kilku wariantów użytego sąsiedztwa kriginowego, świadczą (rys. 13a–14c), iż uwzględnienie w obliczeniach sąsiedztwa ustalonego daje możliwość dokładniejszego odzwierciedlenia poszczególnych subpopulacji wartości estymowanych Z^* mocy elektrycznych P .

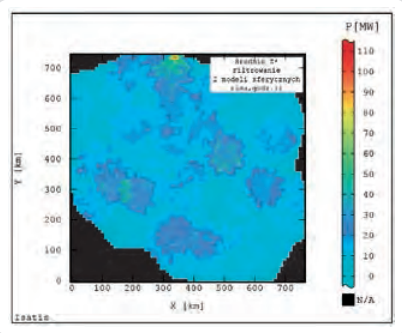
Gdy przyjmuje się sąsiedztwo ruchome o różnych parametrach wyszukiwania próbek (rys. 13a–13b; 14b–14c) uzyskuje się skrajnie asymetryczne, jednoskrzydłowe histogramy rozkładów. W zestawieniu z histogramem sporządzonym dla okresu letniego, z dominującą 1 klasą modalną (rys. 13c), na histogramie dotyczącym okresu zimowego

wyraźnie przeważają 2 klasy modalne, tylko z niewielką przewagą większych wartości średnich Z^* mocy (rys. 14a).


7. Filtrowanie składowych modeli wariogramów obciążeń elektrycznych z zastosowaniem krigingu zwyczajnego
Rezultaty filtrowania poszczególnych




Rys. 16a. Mapa rastrowa rozkładu średnich estymowanych Z^* mocy elektrycznych; filtrowanie efektu samorodków C_0 – zima, godz. 11.00; kriging zwyczajny punktowy, sąsiedztwo ruchome ($4 \times 8 \times 3$)



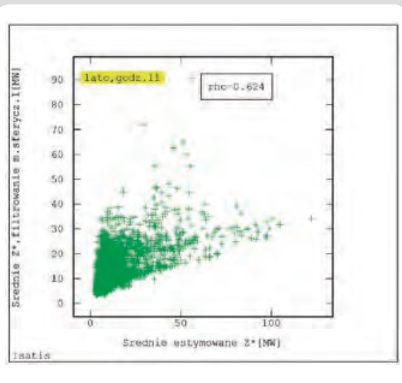
Rys. 16b. Mapa rastrowa rozkładu średnich estymowanych Z^* mocy elektrycznych; filtrowanie składowych (funkcji sferycznych) złożonego modelu teoretycznego – zima, godz. 11.00; kriging zwyczajny punktowy, sąsiedztwo ruchome ($4 \times 8 \times 3$)




Rys. 16c. Mapa rastrowa rozkładu wartości różnic średnich estymowanych $Z^*(v1)$ i średnich Z^* odpowiadających złożonemu modelowi teoretycznemu ($v2$) – zima, godz. 11.00 ($v3 = v1 - v2$); kriging zwyczajny punktowy, sąsiedztwo ruchome ($4 \times 8 \times 3$)




Rys. 17a. Wykres rozrzutu całkowitych średnich Z^* i średnich Z^* po odfiltrowaniu efektu samorodków C_0 – okres letni, godz. 11.00; kriging zwyczajny punktowy




Rys. 17b. Wykres rozrzutu całkowitych średnich Z^* i średnich Z^* po odfiltrowaniu 1 składowej modelu sferycznego – okres letni, godz. 11.00; kriging zwyczajny punktowy




Rys. 17c. Wykres rozrzutu całkowitych średnich Z^* i średnich Z^* po odfiltrowaniu 2 składowej modelu sferycznego – okres letni, godz. 11.00; kriging zwyczajny punktowy



Rys. 18a. Wykres rozrzutu całkowitych średnich Z^* i średnich Z^* po odfiltrowaniu efektu samorodków C_0 – okres zimowy, godz. 11.00; kriging zwyczajny punktowy



Rys. 18b. Wykres rozrzutu całkowitych średnich Z^* i średnich Z^* po odfiltrowaniu 1 składowej modelu sferycznego – okres zimowy, godz. 11.00; kriging zwyczajny punktowy



Rys. 18c. Wykres rozrzutu całkowitych średnich Z^* i średnich Z^* po odfiltrowaniu 2 składowej modelu sferycznego – okres zimowy, godz. 11.00; kriging zwyczajny punktowy

składowych modeli semiwariogramów mocy elektrycznych, dokonano z zastosowaniem kriginu zwyczajnego – punktowego i przyjęciem sąsiedztwa ruchomego ($4 \times 8 \times 3$), zamieszczono w tab. 7 i 8.

W następstwie przeprowadzenia filtrowania uzyskano następujące mapy rastrowe rozkładu mocy elektrycznej P dla rozważanych okresów – letniego i zimowego:

- mapa rastrowa rozkładu średnich $Z^*(v1)$
- mapa rastrowa rozkładu średnich Z^* , po aktywowaniu filtrowania składowej o krótkiej skali modelu sferycznego ($v2$)
- mapa rastrowa rozkładu średnich Z^* , po aktywowaniu filtrowania składowej o dużej skali modelu sferycznego ($v2$)
- mapa rastrowa rozkładu średnich Z^* , tj. różnic $v3 = v1 - v2$
- mapa rastrowa rozkładu średnich Z^* ,

po aktywowaniu filtrowania składowej losowej – efektu samorodków C_0 . Mapa rozkładu średnich estymowanych Z^* mocy P , obliczona z użyciem kriginu zwyczajnego – punktowego, stanowiła płaszczyznę odniesienia podczas przeprowadzania analiz. Porównywano ją z wymienionymi wyżej mapami, sporządzonymi po aktywowaniu filtrowania. Obliczono również mapę rozkładu różnic $v3 = v1 - v2$,

tj. średnich estymowanych Z^* – $v1$ oraz średnich Z^* wyznaczonych dla składowych odpowiadających złożonemu modelowi (sferycznemu), przybliżającemu przebiegi semiwariogramów empirycznych mocy – $v2$.

Filtrowanie wyłącznie efektu samorodków C_0 nie powoduje różnicy w obrazie całkowitej zmienności, ponieważ stosowanie krigingu samo w sobie jest działaniem odfiltrowującym efekt C_0 , prowadzącym do wygładzenia, wyrównania zmian. Celem takiej operacji jest pokazanie pewnych różnic, pojawiających się jedynie wówczas, kiedy wzięły przyjętej siatki elementarnej nie będą pokrywać się z pozycjami danych szacujących, czyli wchodzących do estymacji.

Należy pamiętać, że oceny krigingowe (wartości średnich estymowanych Z^* i standardowe odchylenia estymacji σ_k) zostały obliczone w węzłach siatki elementarnej pokrywającej rozpatrywany obszar, w tym przypadku Polski, zaś pomiary mocy nie zawsze były dokonywane w tychże miejscach. Zatem przeprowadzenie filtrowania powinno być pomocne w pokazaniu lokalizacji, z ujawniającym się efektem samorodków C_0 , odzwierciedlającym wyższy poziom wartości mocy P .

Analizując mapy rastrowe rozkładów (rys. 15a–16c) i wykresy rozrzutu całkowitych średnich estymowanych Z^* i średnich Z^* , reprezentujących pierwszą składową złożonego modelu teoretycznego (1 model sferyczny) wariogramów, stwierdzono występowanie dużej współzależności tych wartości, $r = 0,624$ (lato) i $r = 0,719$ (zima) (rys. 17a–18c). Jednakże w przypadku analizowania współzależności średnich Z^* i średnich Z^* , stanowiących drugą składową tego modelu (2 model sferyczny), można zauważyć, że jest to najsilniejsza współzależność, na co wskazuje współczynnik korelacji $r = 0,959$ (lato) i $r = 0,99$ (zima) (rys. 17c–18c). Świadczy to o tym, że całkowitą zmienność mocy elektrycznej lepiej odzwierciedla model sferyczny, ujmujący wielkoskalowe zmiany, w połączeniu z efektem samorodków C_0 , co pokazują przebiegi semiwariogramów (rys. 5–8), zwłaszcza dla okresu zimowego. Biorąc pod uwagę fakt, że modelowanie zostało przeprowadzone dla dużego obszaru, tj. powierzchni całego kraju, wydaje się to oczywiste. Wykresy rozrzutu całkowitych średnich estymowanych Z^* i średnich Z^* odpowiadających efektowi samorodków C_0 , obliczone dla obu rozważanych momentów czasowych, świadczą o bardzo wysokiej korelacji tychże wartości ($r = 0,97$ dla lata, $r = 0,99$ dla zimy).

8. Podsumowanie

W artykule przedstawiono metodykę analizy i modelowania powierzchniowej zmienności mocy elektrycznych, z wykorzystaniem dwóch technik estymacyjnych – krigingu zwyczajnego i krigingu lognormalnego. Za optymalną metodę szacowania średnich mocy elektrycznych w sieci 110 kV należy uznać kriging zwyczajny, połączony z filtrowaniem poszczególnych składowych przyjętych modeli semiwariogramów empirycznych mocy.

Zaproponowane podejście badawcze w analizie zmienności przestrzenno-czasowej, tj. filtrowanie składowych modeli semiwariogramów obciążeń, z zastosowaniem krigingu zwyczajnego, jest oryginalną metodyką badawczą, dotychczas niestosowaną w modelowaniu powierzchniowej zmienności mocy elektrycznych.

Rezultaty filtrowania procesu zmienności przestrzenno-czasowej obciążeń elektrycznych, przedstawione na mapach rastrowych rozkładów, pozwoliły na zorientowanie się w zakresach i charakterze zmian wartości mocy na obszarze całego kraju, a także w czasie, w dwóm sezonach roku – letnim i zimowym, oraz określenie wpływu dominującej składowej w ogólnej zmienności mocy.

Bibliografia

- Namysłowska-Wilczyńska B., Wilczyński A., Filtrowanie składowych modeli wariogramów mocy elektrycznej w krajowej sieci 110 kV z zastosowaniem krigingu, VII Krajowa Konferencja Naukowa INFOBAZY 2014, Inspiracja•Integracja•Implementacja, Politechnika Gdańska, Instytut Oceanologii PAN, TASK Centrum Informatyczne Trójmiejskiej Akademickiej Sieci Komputerowej, Gdańsk – Sopot, 8–10 września 2014, Materiały konferencyjne, wersja elektroniczna, pełna wersja referatu, Referat krajowy, Streszczenie w języku polskim, s. 43–44; Filtering the components in models of electrical power variograms for national 100 kV network using kriging estimation. Streszczenie w języku angielskim, s. 44–45.
- Namysłowska-Wilczyńska B., Studium modelowania i szacowania porfirowego złoża miedzi Rio Blanco w Peru. 3D modelling and estimation of Rio Blanco porphyritic copper deposit in Peru, *Prace Wrocławskiego Towarzystwa Naukowego* seria B, nr 220. KOMPUTEROWE WSPOMAGANIE BADAŃ NAUKOWYCH XXI, Wrocław 2014, s. 53–65.
- Namysłowska-Wilczyńska B., Analizy przestrzenne z zastosowaniem metod geostatystycznych. Modelowanie 3D porfirowego złoża miedzi Rio Blanco w Peru, *Roczniki Geomatyki (Annals of Geomatics)* 2007, Polskie Towarzystwo Informatyki Przestrzennej, Warszawa, t. V, z. 1, s. 91–103.
- Namysłowska-Wilczyńska B., Geostatistical methods used to estimate Sieroszowice copper ore deposit parameter, *Zeitschrift für Geologische Wissenschaften, Journal for the Geological Sciences*, Berlin 2012, 40 (6), s. 329–361.
- Namysłowska-Wilczyńska B., Uncertainty estimation through geostatistical simulations Geomin 2013 3rd International Seminar on Geology for the Mining Industry, 24–26 July 2013, Santiago, Chile. Proceedings GEOMIN 2013. Chapter 2 Modeling and Geostatistics. Gecamin Publications, Edit. Jozsef Ambrus et al., s. 63–70.

- Namysłowska-Wilczyńska B., Skorupska B., Wieniewski A., Analiza geostatystyczna zmienności parametrów technologicznych popiołozużył zdeponowanych na składowiska odpadów przemysłowych, *Ochrona Środowiska* 2012, Vol. 34, nr 2, s. 43–48.
- Namysłowska-Wilczyńska B., Wilczyński A., Analiza obciążeń sieci NN i 110 kV zamkniętej z wykorzystaniem optymalizacji geostatystycznej, Część I, Raport serii SPR nr 13/2002, wykonany na zlecenie PSE S.A., Instytut Geotechniki i Hydrotechniki Politechniki Wrocławskiej, Wrocław 2002.
- Namysłowska-Wilczyńska B., Wilczyński A., Funkcja wariogramu jako narzędzie badania zmienności obciążeń elektrycznych w układzie powierzchniowym, *Elektroenergetyka* 2003, nr 4, s. 18–34.
- Namysłowska-Wilczyńska B., Wilczyński A., Zastosowanie metod geostatystycznych do analizy przestrzennej zmienności obciążeń elektrycznych dla obszaru Polski, *Roczniki Geomatyki* 2005, t. III, z. 2, Polskie Towarzystwo Informatyki Przestrzennej, s. 125–134.
- Namysłowska-Wilczyńska B., Wilczyński A., Tymorek A., Modelowanie powierzchniowe obrazu zmian obciążeń elektrycznych z zastosowaniem krigingu lognormalnego, *Elektroenergetyka* 2004, nr 1, s. 1–15.
- Namysłowska-Wilczyńska B., Wilczyński A., Spatial Electrical Loads Modeling Using the Geostatistical Methods, International CODATA Conference 2004 “The Information Society: New Horizons for Science”, Berlin, Germany, 7–10 November 2004, s. 25. pdf paper, [online] <http://www.codata.org/04conf/paper/Namyslowska-Wilczynska-paper>.
- Wilczyński A., Modelowanie powierzchniowe obciążeń elektrycznych z wykorzystaniem krigingowej metody estymacyjnej, *Archiwum Energetyki* 2004, nr 1–2, s. 31–50.
- Namysłowska-Wilczyńska B., Wilczyński A., 3D Electric Power demand forecasting as a tool for planning electrical Power firm's activity by means of geostatistical methods, *Econometrics. Forecasting* 2010, nr 28, Research Papers of Wrocław University of Economics, No 91, s. 95–112.
- Namysłowska-Wilczyńska B., Wilczyński A., Structural analysis of variation of electricity transmission marginal costs, *Econometria. Econometrics* 2014, nr 1 (39), Research Papers of Wrocław University of Economics, s. 71–84.
- Namysłowska-Wilczyńska B., Wilczyński A., Geostatistical model (2D) of the surface distribution of electricity transmission marginal costs. *Econometria. Econometrics* 2013, No 1 (39), Research Papers of Wrocław University of Economics, s. 85–99.
- Namysłowska-Wilczyńska B., Geostatistical hydrogeochemical 3D model for Kłodzko underground water intake area. Part I. Estimation of Basic statistics on quality parameters of underground waters, *Studia Geotechnica et Mechanica* 2014, Vol. XXXV, nr 1, s. 157–181.

17. Armstrong M., Basic Linear Geostatistics, Springer, Berlin 1998.
 18. Namysłowska - Wilczyńska B., Geostatystyka – Teoria i Zastosowania, Oficyna Wydawnicza Politechniki Wrocławskiej, Wrocław, 2006.
-

Barbara Namysłowska-Wilczyńska

prof. dr hab.

Politechnika Wroclawska

e-mail: Barbara.Namyslowska-Wilczynska@pwr.edu.pl

Zajmuje się problemami naukowymi związanymi z modelowaniem, szacowaniem i prognozowaniem parametrów złóż surowców mineralnych, a w szczególności złóż rud miedzi. Jej prace są związane z różnorodnymi zastosowaniami metod statystycznych i geostatystycznych (statystyki stosowanej – przestrzennej), w tym technik symulacyjnych (symulacji warunkowej i niewarunkowej), w zagadnieniach dotyczących geologii złóżowej, górniczej, środowiskowej i inżynierskiej, ochrony środowiska, w badaniach składowisk odpadów, klimatologii, enzymologii, geodezji, a także w energetyce. Autorka bardzo wielu artykułów i prac badawczych poświęconych analizom przestrzennym i przestrzenno-czasowym (3D), oszacowaniu niepewności oraz analizie ryzyka zmienności badanych parametrów, stosowanych w rozwiązywaniu wybranych zagadnień. Ostatnie badania obejmują opracowanie geostatystycznych (3D) modeli hydrogeochemicznych zmienności parametrów jakościowych wód podziemnych dla obszaru ujęć wody i wody w sieci. Zastępca kierownika Centrum Modelowania Procesów Hydrologicznych (CMPH) we Wrocławiu. Profesor tytularny.

Artur Wilczyński

prof. dr hab. inż.

Politechnika Wroclawska

e-mail: artur.wilczynski@pwr.edu.pl

Zajmuje się problemami naukowymi związanymi z planowaniem i eksploatacją systemów elektroenergetycznych. Jego prace badawcze dotyczą m.in. modelowania i prognozy procesów obciążeń elektrycznych, także w układzie (2D) i (3D), bezpieczeństwa elektroenergetycznego, badania struktury systemów taryfowych i ich oddziaływanie na pobór energii elektrycznej, restrukturyzacji elektroenergetyki oraz tworzenia rynków energii, integracji generacji rozproszonej z systemem elektroenergetycznym, modelowania zanieczyszczenia środowiska naturalnego. Profesor zwyczajny Politechniki Wrocławskiej.