

Agata Żółtaszek, Alicja Olejnik

Uniwersytet Łódzki

Wydział Ekonomiczno-Socjologiczny

AŻ: agata.zoltaszek@uni.lodz.pl,  <https://orcid.org/0000-0003-3657-288X>

AO: alicia.olejnik@uni.lodz.pl,  <https://orcid.org/0000-0002-8542-3250>

Przestrzenna ocena efektywności wykorzystania zasobów innowacyjnych w gospodarkach regionalnych: analiza SDEA-INI z uwzględnieniem ICT i AI

Zarys treści: Celem artykułu jest ocena efektywności cyfrowo-innowacyjnej regionów NUTS 2 Europy w 2025 r. z uwzględnieniem nakładów na ICT, AI, B+R oraz zatrudnienia w sektorach wysokich technologii. Zastosowano model SDEA-INI (Spatial Data Envelopment Analysis with Independent Neighbour Inputs), biorący pod uwagę zależności przestrzenne. Na podstawie wyników opracowano klasyfikację RDIEC i porównano ją z RIS. Wyniki wskazują na znaczne zróżnicowanie efektywności – jedynie 6% regionów osiąga pełną efektywność. Sąsiedztwo liderów nie gwarantuje podobnych rezultatów, co potwierdza zróżnicowaną zdolność regionów do absorpcji wiedzy i wykorzystania zasobów.

Słowa kluczowe: efektywność cyfrowo-innowacyjna, sztuczna inteligencja (AI), technologie informacyjno-komunikacyjne (ICT), przestrzenna analiza obwiedni danych z niezależnymi nakładami przestrzennymi (SDEA-INI), rozwój regionalny

Wprowadzenie

Technologie cyfrowe, a w szczególności technologie informacyjno-komunikacyjne (ICT, ang. *Information and Communication Technologies*) oraz sztuczna inteligencja (AI, ang. *Artificial Intelligence*), należą obecnie do najważniejszych czynników kształtujących produktywność, innowacyjność i rozwój gospodarczy (Fu i in. 2026, Kharod, Kaur 2026). W gospodarce postpandemicznej ich znaczenie systematycznie wzrasta, wpływając zarówno na funkcjonowanie przedsiębiorstw, jak i na procesy zachodzące na poziomie sektorów oraz regionów. Liczne badania wskazują, że AI i automatyzacja, wspierane przez chmury obliczeniowe, handel elektroniczny, analizy dużych zbiorów danych oraz rozwiniętą infrastrukturę cyfrową, stanowią istotne źródło transformacji gospodarczej. Technologie te

przyczyniają się do wzrostu produktywności poprzez automatyzację rutynowych zadań, usprawnienie procesów decyzyjnych oraz zwiększenie zdolności innowacyjnych organizacji i całych gospodarek (Premavathi i in. 2025, Chakraborty, Panda 2026).

Jednocześnie rozwój ICT tworzy podstawy umożliwiające efektywne wdrażanie rozwiązań opartych na sztucznej inteligencji. Chmura obliczeniowa oraz zasoby internetowe zapewniają infrastrukturę niezbędną do wykorzystania zaawansowanych aplikacji cyfrowych (Kayalvili i in. 2025, Zac i in. 2026), podczas gdy technologie e-commerce oraz analityka danych wspierają optymalizację procesów biznesowych, efektywne wykorzystanie zasobów i wzrost konkurencyjności przedsiębiorstw (Yu i in. 2025, Wang i in. 2026). W konsekwencji ICT i AI są coraz częściej postrzegane jako komplementarne elementy ekosystemu cyfrowego, które wspólnie wpływają na tempo rozwoju gospodarczego i zdolność regionów do generowania innowacji (Criveanu 2026, Pan 2026).

Z perspektywy współczesnych teorii rozwoju regionalnego technologie cyfrowe stanowią jeden z kluczowych czynników rozwoju gospodarki opartej na wiedzy (ang. *Knowledge Economy*), jednak ich oddziaływanie na wzrost gospodarczy zależy od zdolności regionów do tworzenia, absorpcji i dyfuzji wiedzy. Koncepcje *Learning Regions*, *Knowledge Regions* oraz *Regional Innovation Systems* (RIS) podkreślają, że przewaga konkurencyjna regionów wynika nie tylko z poziomu nakładów na działalność innowacyjną, lecz również z jakości współpracy pomiędzy przedsiębiorstwami, jednostkami naukowymi i administracją publiczną, zdolności absorpcyjnych (ang. *absorptive capacity*) oraz jakości otoczenia instytucjonalnego. Jednocześnie procesy innowacyjne mają charakter przestrzenny i sieciowy, a ich efektywność jest wzmacniana przez efekty aglomeracji oraz przepływy wiedzy pomiędzy regionami (ang. *knowledge spillovers*). W tym ujęciu technologie ICT i AI mogą zwiększać produktywność przedsiębiorstw oraz wspierać tworzenie i dyfuzję wiedzy, jednak skala uzyskiwanych efektów pozostaje osadzona w charakterystycznym dla danego regionu ekosystemie instytucjonalnym, organizacyjnym i gospodarczym. W konsekwencji regiony dysponujące podobnym poziomem zasobów cyfrowych i innowacyjnych mogą osiągać odmienne rezultaty gospodarcze (Mosconi, D’Ingiullo 2023, Aparicio-Pérez i in. 2025).

Na poziomie regionalnym infrastruktura ICT, poziom kompetencji cyfrowych oraz zdolność do absorpcji nowych technologii stanowią kluczowe determinanty produktywności i konkurencyjności. Wyniki badań empirycznych potwierdzają pozytywny wpływ cyfryzacji na wydajność pracy, modernizację struktur gospodarczych, rozwój innowacji oraz wzrost zatrudnienia (Banday, Erdem 2024). W literaturze podkreśla się również, że procesy związane z transformacją cyfrową mają charakter przestrzenny – rozwój technologiczny, przepływ wiedzy i dyfuzja innowacji nie ograniczają się do granic administracyjnych, lecz oddziałują na sąsiadujące regiony, tworząc sieci wzajemnych zależności i efekty rozlewania się (ang. *spillover effects*) (Abdeljawad i in. 2023, Ilham i in. 2025).

Rosnące znaczenie cyfryzacji znajduje odzwierciedlenie w badaniach wykorzystujących metodę Data Envelopment Analysis (DEA) do oceny efektywności wykorzystania zasobów cyfrowych. DEA była stosowana m.in. do analizy

efektywności systemów ICT, oceny potencjału transformacji cyfrowej regionów, badania efektywności gospodarki cyfrowej w krajach Unii Europejskiej oraz analizy zależności między cyfryzacją a wynikami gospodarczymi i środowiskowymi (Mitrović 2020, Amiri i in. 2023). Wyniki tych badań potwierdzają przydatność DEA jako narzędzia umożliwiającego ocenę stopnia, w jakim nakłady cyfrowe przekładają się na rezultaty gospodarcze i innowacyjne.

Pomimo rosnącej liczby analiz występują jednak istotne luki badawcze. Po pierwsze, większość dotychczasowych badań uwzględnia wyłącznie tradycyjne wskaźniki cyfryzacji związane z ICT, natomiast sztuczna inteligencja nie jest traktowana jako odrębny czynnik wejściowy w modelach DEA (Song, Han 2023, Li i in. 2026). Biorąc pod uwagę coraz większą rolę AI w kształtowaniu produktywności i innowacyjności, brak jej bezpośredniego uwzględnienia ogranicza możliwości kompleksowej oceny efektywności cyfrowej regionów (Fu i in. 2026). Po drugie, klasyczne modele DEA zakładają niezależność analizowanych jednostek, pomijając przestrzenny charakter procesów rozwoju regionalnego.

W związku z powyższym zasadne jest zastosowanie metody analitycznej uwzględniającej zarówno wieloaspektowy charakter cyfryzacji, jak i przestrzenne współzależności pomiędzy regionami. W niniejszym badaniu przyjęto, że technologie ICT i AI oddziałują na rozwój gospodarczy pośrednio – poprzez zwiększanie zdolności przedsiębiorstw do tworzenia i absorpcji innowacji, poprawę produktywności oraz efektywniejsze wykorzystanie zasobów regionalnych. Skuteczność tego mechanizmu zależy jednak od komplementarnych zasobów (regionu i jego sąsiadów), takich jak działalność badawczo-rozwojowa, kapitał ludzki oraz otoczenie instytucjonalne, co oznacza, że podobny poziom nakładów cyfrowych może prowadzić do odmiennych rezultatów gospodarczych. Przyjęte podejście pozwala pełniej uchwycić procesy, za pomocą których ICT i AI wpływają na rozwój gospodarczy regionów.

Celem artykułu jest ocena efektywności cyfrowo-innowacyjnej regionów NUTS2 Europy w 2025 r. z uwzględnieniem nakładów cyfrowych (ICT i AI), wydatków na badania i rozwój oraz zatrudnienia w sektorach wysokich technologii. W badaniu zastosowano model SDEA-INI (ang. *Spatial Data Envelopment Analysis with Independent Neighbour Inputs*), który umożliwia jednoczesne uwzględnienie przestrzennych zależności występujących pomiędzy gospodarkami regionalnymi oraz niekontrolowalności nakładów przestrzennych. Analiza ma na celu identyfikację stopnia, w jakim nakłady związane z ICT i AI przekładają się na rezultaty gospodarcze. Dodatkowo w oparciu o wyniki modelu SDEA-INI opracowano ranking efektywności cyfrowo-innowacyjnej regionów (RDIEC, ang. *Regional Digital-Innovation Efficiency Classification*), umożliwiający identyfikację jednostek wzorcowych oraz ocenę przestrzennego zróżnicowania efektywności wykorzystania zasobów cyfrowych i rozwojowych. Ponadto wyniki rankingu RDIEC zestawiono z klasyfikacją Komisji Europejskiej RIS, co pozwoliło na porównanie poziomu innowacyjności regionów z efektywnością wykorzystania ich potencjału innowacyjnego. Wypełniając istniejącą lukę badawczą, artykuł stanowi jedną z pierwszych prób integracji wskaźników AI i ICT w przestrzennym modelu DEA służącym do oceny cyfrowo-innowacyjnej efektywności rozwoju regionalnego.

Dane

Badanie obejmuje 237 regionów NUTS 2 kontynentalnej Unii Europejskiej oraz Norwegii. Wszystkie wykorzystane dane pochodzą z bazy Eurostat. Poziom rozwoju gospodarczego regionów określono za pomocą produktu krajowego brutto (PKB) per capita wyrażonego w parytecie siły nabywczej (Valero, van Reenen 2019). Aby zapewnić możliwie najbardziej aktualną ocenę potencjału innowacyjnego regionów, wykorzystano najnowsze dostępne dane regionalne dla okresu 2010–2024 (z wyjątkiem: od 2012 dla Rumunii; do 2021 dla Norwegii). Następnie dokonano predykcji wartości PKB per capita dla 2025 r. na podstawie średniorocznego tempa zmian. Warto podkreślić, że PKB stanowi syntetyczną miarę poziomu rozwoju, która pośrednio odzwierciedla efekty działalności innowacyjnej, nie będąc jej bezpośrednim miernikiem.

Badania empiryczne wskazują, że nakłady na badania i rozwój (B+R) charakteryzują się wysoką persystencją, a ich poziom jest w dużej mierze determinowany wartościami z okresów poprzednich oraz poziomem dochodu gospodarczego (Bravo-Ortega, García Marín 2011). Literatura tematu potwierdza również, że wpływ tych wydatków na wzrost gospodarczy ma charakter długookresowy, a jego efekty ujawniają się dopiero z upływem czasu (Aiginger, Falk 2005, Falk 2007). W niektórych badaniach wykazano wręcz wieloletnie opóźnienia, jak np. w analizie gospodarki Tajwanu, gdzie efekty inwestycji B+R były odczuwalne dopiero po około czterech latach (Lin 2006, Abid 2025). Zatem ze względu na spodziewane opóźnienia uwidaczniania się efektów B+R, jako reprezentatywną wartość nakładu determinującego poziom PKB per capita w roku 2025 w niniejszym badaniu zastosowano średnią wydatków na B+R, dokładniej nakładów krajowych brutto na działalność badawczą i rozwojową (GERD, ang. *Gross Domestic Expenditure on Research and Development*) z lat 2022–2024 w ujęciu parytetu siły nabywczej (PPS) na mieszkańca w cenach stałych (c.s.) z 2005 r.

W analizie przyjęto, że obok nakładów GERD istotnymi determinantami efektywności cyfrowo-innowacyjnej są także:

1. **intensywność ICT** (Oliinyk i in. 2024, Pažun i in. 2025), mierzona czterema zmiennymi odzwierciedlającymi poziom zaawansowania technologicznego gospodarki: udziałem przedsiębiorstw, w których ponad 50% pracujących ma dostęp do Internetu do celów służbowych, korzystających z usług przetwarzania w chmurze, prowadzących sprzedaż internetową oraz wykorzystujących analitykę danych;
2. **adaptacja technologii AI** (Wang i in. 2021), mierzona udziałem przedsiębiorstw wykorzystujących co najmniej jedno narzędzie sztucznej inteligencji;
3. **zatrudnienie** w sektorach wysokiej techniki (Coronel, Díaz-Roldán 2025), mierzone udziałem pracujących w sektorach wysokich technologii; należy podkreślić, że część wykorzystanych zmiennych, w szczególności wskaźnik adaptacji AI, odzwierciedla stopień rozpowszechnienia technologii cyfrowych w przedsiębiorstwach, a nie intensywność, zaawansowanie czy skuteczność ich zastosowania; użyte wskaźniki należy zatem interpretować jako miary

Tabela 1. Podstawowe statystyki

	definicja zmiennej	zmienna	średnia	odchylenie	min.	maks.
intensywność ICT	przedsiębiorstwa korzystające z usług przetwarzania w chmurze, ang. <i>cloud computing</i> , jako odsetek przedsiębiorstw, w których pracujący mają dostęp do Internetu	CLOUD	50,3	17,0	9,2	89,0
	przedsiębiorstwa wykorzystujące analitykę danych realizowaną przez własnych pracowników lub podmioty zewnętrzne, ang. <i>data analytics</i> , jako odsetek przedsiębiorstw	D_ANALYTICS	37,8	9,9	15,7	64,7
	przedsiębiorstwa, w których ponad 50% pracujących ma dostęp do Internetu do celów służbowych, ang. <i>Internet</i> , jako odsetek przedsiębiorstw	INTERNET	53,2	15,6	17,3	90,9
	przedsiębiorstwa prowadzące sprzedaż internetową, ang. <i>e-commerce</i> , jako odsetek przedsiębiorstw, w których pracujący mają dostęp do Internetu	eCOMMERCE	20,6	5,9	7,9	45,4
adaptacja AI	przedsiębiorstwa wykorzystujące co najmniej jedno narzędzie sztucznej inteligencji, ang. <i>AI</i> , jako odsetek przedsiębiorstw	AI	19,5	10,0	1,8	50,8
nakłady rozwojowe	nakłady krajowe brutto na działalność badawczą i rozwojową, ang. <i>Gross Domestic Expenditure on Research and Development</i> ; średnia: 2022–2024, per capita wyrażonego w parytecie siły nabywczej (c.s. 2005)	GERD	531,6	530,3	13,4	3825,0
	zatrudnienie w sektorach wysokich technologii, ang. <i>employment</i> , jako odsetek ogółu pracujących	EMPLOYMENT	4,6	2,4	0,8	14,3
efekty	produkt krajowy brutto (ang. <i>Gross Domestic Product</i>) per capita wyrażonego w parytecie siły nabywczej	PKB	38932,1	13440,9	16828,9	100230,5

Źródło: opracowanie własne.

poziomu wdrożenia rozwiązań cyfrowych, wynikające z dostępności porównywalnych danych regionalnych Eurostatu.

W odróżnieniu od GERD zmienne te charakteryzują się przede wszystkim bieżącym oddziaływaniem na aktywność gospodarczą (Tripathi, Inani 2020, Drago i in. 2025, Kachunga i in. 2025). W związku z tym ich wykorzystanie jako nakładów determinujących poziom PKB per capita w 2025 r. jest metodologicznie uzasadnione. Dodatkową zaletą jest dostępność danych dla wszystkich analizowanych wskaźników w bazie Eurostatu za rok 2025.

Brak danych na poziomie regionalnym uzupełniano z wykorzystaniem procedur dezagregacji przestrzennej oraz ekstrapolacji opartej na danych dostępnych dla wyższych poziomów agregacji terytorialnej (krajowych lub NUTS 1). W przypadku regionów, dla których dostępne były wyłącznie dane odnoszące się do jednostek nadrzędnych, dla zmiennych zatrudnienia i wydatków GERD wartości przypisywano jednostkom niższego szczebla, zaś dla miar ICT i AI szacowano wartości dla regionów NUTS 2 z wykorzystaniem wag odzwierciedlających względny poziom innowacyjności regionów oparty na opracowanym przez Komisję Europejską *Regional innovation index 2025* (RIS 2025). Zastosowane podejście pozwoliło zachować pełną porównywalność przestrzenną analizowanych wskaźników przy jednoczesnym ograniczeniu wpływu braków danych na uzyskane wyniki.

Na podstawie statystyk opisowych zawartych w tabeli 1 można stwierdzić, że analizowane regiony różnią się pod względem poziomu wykorzystania nakładów związanych z cyfryzacją i rozwojem gospodarczym. W grupie nakładów ICT najwyższe średnie wartości osiąga dostęp do Internetu w przedsiębiorstwach (53,2%) oraz wykorzystanie usług chmurowych (50,3%), przy umiarkowanym zróżnicowaniu międzyregionalnym, natomiast nieco niższy poziom obserwuje się dla analityki danych (37,8%), a wyraźnie niższy dla e-commerce (20,6%). Adaptacja sztucznej inteligencji pozostaje relatywnie ograniczona (19,5%) i silniej zróżnicowana przestrzennie, co wskazuje na jej wczesny etap upowszechnienia. Istotne dysproporcje widoczne są również w przypadku pozostałych nakładów rozwojowych – zarówno nakłady na działalność badawczo-rozwojową (średnio 531,6), jak i zatrudnienie w sektorach wysokich technologii (4,6%) cechują się znaczną zmiennością, podobnie jak poziom efektu gospodarczego mierzonego PKB per capita (średnio 38,9 tys. PPS). Zróżnicowanie to sugeruje, że regiony wykorzystują odmienne kombinacje nakładów w procesie generowania efektów, co stanowi podstawę do dalszej analizy ich efektywności w ujęciu DEA.

Metodologia

W niniejszym artykule zastosowano autorską metodę SDEA-INI (Spatial Data Envelopment Analysis with Independent Neighbour Inputs), stanowiącą rozwinięcie klasycznej analizy obwiedni danych (DEA) oraz jej przestrzennego rozszerzenia, tj. SDEA. Metoda ta umożliwia ocenę efektywności wykorzystania nakładów innowacyjnych, w szczególności cyfrowych, w regionalnych gospodarkach,

przy uwzględnieniu zarówno wewnętrznych zasobów regionów, jak ich przestrzennych odpowiedników wynikających z sąsiedztwa geograficznego.

Punktem wyjścia dla metody SDEA-INI jest klasyczny model DEA opracowany przez Charnesa, Coopera i Rhodesa (CCR) (Charnes i in. 1978), który umożliwia ocenę względnej efektywności jednostek decyzyjnych (DMU) poprzez porównanie relacji między nakładami [ang. *inputs*, (x_k^i)] a osiąganymi przez jednostki efektami [ang. *outputs*, (y_k^i)]. Ponieważ celem badania było porównanie względnej efektywności regionów przy założeniu wspólnej technologii produkcji, a nie ocena zróżnicowania efektów skali, do analizy wykorzystano model CCR. W podejściu tym efektywność regionu definiowana jest jako maksymalny możliwy stosunek ważonych efektów do ważonych nakładów przy założeniu, że żaden z analizowanych regionów nie może osiągać efektywności przekraczającej wartość równą 1. W praktyce efektywność ta jest rozumiana jako stopień, w jakim dany region mógłby ograniczyć wykorzystanie zasobów, zachowując obecny poziom efektów. W niniejszym badaniu pojęcie nakładów ma charakter funkcjonalny i nie oznacza klasycznych nakładów w rozumieniu ekonomicznej funkcji produkcji, lecz zmienne opisujące zasoby i uwarunkowania, które mogą wpływać na osiąganе rezultaty gospodarcze, co jest podejściem obecnym w regionalnych badaniach efektywności (Ramzi i in. 2016, Łacka, Brzezicki 2025).

W opracowanym przez Olejnik i in. (2021) rozszerzonym modelu Spatial DEA (SDEA) przyjmuje się, że efektywność regionu może być kształtowana nie tylko przez jego własne zasoby i efekty, lecz także przez potencjał regionów sąsiednich. Zależności przestrzenne opisano za pomocą macierzy wag przestrzennych W , określającej intensywność oddziaływań między regionami. W ramach SDEA uwzględnia się trzy rodzaje efektów przestrzennych: nakłady przestrzenne (zasoby sąsiednich regionów wspierające działalność badanego regionu, ang. *spatial inputs*), nakłady przestrzenne produktowe (efekty sąsiadów wykorzystywane jako dodatkowe zasoby, ang. *spatial product inputs*) oraz efekty przestrzenne (efekty działalności regionu obserwowane w wynikach regionów sąsiednich, ang. *spatial outputs*).

Ograniczeniem modelu SDEA jest jednak założenie, że wszystkie zmienne przestrzenne pozostają pod kontrolą badanego regionu. W rzeczywistości wiele czynników występujących w otoczeniu geograficznym ma charakter egzogeniczny i nie może być bezpośrednio kształtowanych przez wewnętrznych decydentów danego regionu. W odpowiedzi na ten problem rozszerzono podejście SDEA, wprowadzając kategorię niezależnych nakładów sąsiedzkich (SDEA-INI, ang. *Independent Neighbour Inputs*) (Olejnik i in. 2026). INI to zmienne przestrzenne wpływające na efektywność regionu, które pozostają poza jego bezpośrednią kontrolą.

Z uwagi na specyfikę badania w poniższej analizie wykorzystano model wyłącznie z niezależnymi nakładami przestrzennymi. W rezultacie współczynnik efektywności wyznaczany jest z rozwiązania następującego programu optymalizacyjnego:

$$\begin{aligned}
& \min \theta^* \\
& \sum_{i=1}^N x_k^i \lambda_i \leq \theta^* x_k^{i_0}, \quad k \in \mathcal{I} \\
& \sum_{i=1}^N \sum_{j=1}^N w_{ij} x_k^j \lambda_i \leq \sum_{j=1}^N w_{i_0 j} x_k^{i_0}, \quad k \in \mathcal{S} \\
& \sum_{i=1}^N y_m^i \lambda_i \geq y_m^{i_0}, \quad m \in \mathcal{O} \\
& 0 \leq \lambda_i, \quad i \in \{1, \dots, N\},
\end{aligned}$$

gdzie N jest liczbą jednostek, a zbiory $\mathcal{I}$, $\mathcal{S}$ i $\mathcal{O}$, zawierają odpowiednio indeksy zmiennych nakładów, nakładów przestrzennych i efektów dla poszczególnych jednostek. Powyższy program został rozwiązany w Octave.

Zastosowane podejście pozwala na bardziej realistyczną ocenę efektywności w warunkach gospodarki cyfrowej, w której dostęp do infrastruktury, wiedzy, kompetencji cyfrowych czy ekosystemów innowacji często wykracza poza granice administracyjne regionów. SDEA-INI umożliwia jednocześnie elastyczny dobór zmiennych przestrzennych oraz określenie, które z nich należy traktować jako kontrolowalne, a które jako egzogeniczne. W efekcie model stanowi szczególnie użyteczne narzędzie do oceny efektywności wykorzystania nakładów innowacyjnych i cyfrowych związanych z ICT i AI.

Wyniki


Do badania cyfrowo-innowacyjnej efektywności gospodarek regionalnych zastosowano model SDEA-INI, który umożliwia uwzględnienie oddziaływania sąsiedztwa, przepływów wiedzy oraz dyfuzji technologii. W badaniu przyjęto, że nakładami są zmienne opisujące intensywność wykorzystania technologii cyfrowych (CLOUD, D_ANALYTICS, INTERNET, eCOMMERCE), adaptację sztucznej inteligencji (AI) oraz nakłady rozwojowe (GERD i EMPLOYMENT), natomiast efektem jest poziom rozwoju gospodarczego mierzony PKB per capita.

Ponieważ zastosowanie podejścia przestrzennego wymaga potwierdzenia występowania zależności przestrzennych, badanie rozpoczęto od konstrukcji macierzy wag przestrzennych. W celu uwzględnienia interakcji przestrzennych między nakładami i efektami, również w przypadku regionów wyspiarskich i brzegowych, zastosowano macierz trzech najbliższych sąsiadów. Następnie przeprowadzono analizę rozkładu przestrzennego oraz ocenę autokorelacji przestrzennej z wykorzystaniem statystyk globalnych i lokalnych (I Morana oraz LISA), co pozwoliło określić skalę i charakter występujących powiązań przestrzennych (Anselin 1995).

Analiza rozkładu przestrzennego zmiennych opisujących intensywność wykorzystania technologii ICT w regionach europejskich, zaprezentowanych na rycinie 1, wskazuje na wyraźne zróżnicowanie geograficzne. Znajduje ono dodatkowe


potwierdzenie w wynikach analizy autokorelacji przestrzennej mierzonej globalnego statystyką *I* Morana oraz zależnościami lokalnymi (LISA). Mapy rozkładu przestrzennego pokazują, że najwyższe wartości wskaźników ICT koncentrują się przede wszystkim w krajach Europy Północnej oraz w części Europy Zachodniej. Szczególnie widoczna jest przewaga regionów skandynawskich, a także wybranych regionów Niemiec, krajów Beneluksu i Francji. Z kolei niższe poziomy intensywności ICT obserwowane są głównie w regionach Europy Centralnej i Wschodniej, co wskazuje na utrzymujące się dysproporcje w zakresie transformacji cyfrowej gospodarek.

W przypadku usług chmurowych widoczna jest silna koncentracja wysokich wartości w regionach Europy Północnej i Zachodniej oraz we Włoszech, przy



Ryc. 1. Analiza przestrzennego zróżnicowania intensywności ICT

Źródło: opracowanie własne w pakiecie GeoDa.



Ryc. 1. cd.

jednoczesnym niższym poziomie we Francji, w części Europy Południowej. Rozkład ten ma wyraźnie klastrowy charakter, co potwierdza bardzo wysoka wartość globalnej statystyki Morana ($I \approx 0,83$).

W przypadku analityki danych obserwowany jest podobny, choć nieco słabszy i mniej jednorodny, schemat przestrzenny niż w przypadku usług chmurowych. Niskie wartości koncentrują się w regionach Europy Centralnej i Wschodniej od Polski po Grecję, z wyjątkiem stolic i krajów nadbałtyckich. Wartość statystyki Morana ($I \approx 0,60$) wskazuje na dość silną autokorelację przestrzenną, co oznacza, że regiony o zbliżonym poziomie wykorzystania analityki danych wykazują tendencję do grupowania się, lecz klastry są mniej rozległe i bardziej fragmentaryczne.

Wyraźniejsze uporządkowanie przestrzenne widoczne jest w przypadku dostępu do Internetu w przedsiębiorstwach (Internet). Rozkład zmiennej wskazuje na wyraźną dominację wysokich wartości w północnej części Europy oraz w wybranych regionach Europy Zachodniej. Wysoka wartość statystyki Morana ($I \approx 0,78$) świadczy o silnej dodatniej autokorelacji przestrzennej, co oznacza, że dostęp do Internetu jest jednym z najbardziej przestrzennie uwarunkowanych komponentów ICT.

Odmiennej charakter ma natomiast handel elektroniczny. Choć na mapie można zidentyfikować regiony o wyższym poziomie sprzedaży internetowej, ich rozmieszczenie jest bardziej rozproszone i nie tworzy tak wyraźnych klastrów jak pozostałe zmienne ICT. Najniższa wartość statystyki Morana ($I \approx 0,56$) spośród analizowanych wskaźników wskazuje, że efekty sąsiedztwa występują, ale są mniej istotne.


Zarówno analiza rozkładu przestrzennego, jak i wyniki autokorelacji przestrzennej wskazują na istnienie silnych, nieprzypadkowych wzorców rozmieszczenia intensywności ICT w przestrzeni europejskiej. Oznacza to, że w modelu SDEA-INI wysoce uzasadnione jest wykorzystanie tych nakładów z uwzględnieniem kontekstu przestrzennego.

Rycina 2 przedstawia przestrzenne zróżnicowanie nakładów rozwojowych (GERD, zatrudnienie w sektorach wysokich technologii) oraz adaptacji sztucznej inteligencji. W adaptacji sztucznej inteligencji obserwujemy stosunkowo silne uporządkowanie przestrzenne. Pomimo że rozkład wartości na mapie nie jest jednorodny, widoczna jest koncentracja wyższych poziomów adaptacji AI w określonych częściach Europy, zwłaszcza w regionach północnych i zachodnich. Wysoka wartość statystyki globalnej Morana ($I \approx 0,78$) potwierdza silną dodatnią autokorelację przestrzenną, co oznacza, że regiony o zbliżonym poziomie wykorzystania AI mają tendencję do grupowania się w przestrzeni. Może to świadczyć o rosnącym znaczeniu procesów dyfuzji technologii oraz powiązań regionalnych w rozwoju sztucznej inteligencji.


Odmiennej charakter ma rozmieszczenie nakładów na działalność badawczo-rozwojową. Choć mapy rozkładu przestrzennego wskazują na pewne zróżnicowanie między regionami, z relatywnie wyższymi wartościami w części Europy Zachodniej i Północnej, układ ten jest jednak mniej zwarty niż w przypadku AI. Potwierdza to wartość statystyki Morana na poziomie około 0,29, która wskazuje na umiarkowaną autokorelację przestrzenną. Oznacza to, że istnieją pewne skupiska regionów o podobnym poziomie nakładów B+R, jednak z wyjątkiem klastra „niskie-niskie” w Europie Centralnej i Wschodniej nie mają one charakteru silnych i rozległych klastrów.

Najniższy stopień regularności przestrzennej obserwuje się w przypadku zatrudnienia w sektorach wysokich technologii. Rozkład tej zmiennej ma rozproszony charakter, a regiony o wyższych wartościach nie tworzą wyraźnych skupisk przestrzennych. Bardzo niska wartość statystyki Morana ($I \approx 0,12$) wynika z koncentracji tych zasobów w dużych ośrodkach miejskich.

Analiza przestrzennego zróżnicowania produktu krajowego brutto per capita została zaprezentowana na rycinie 3. Obserwuje się wyraźną koncentrację



Ryc. 2. Analiza przestrzennego zróżnicowania nakładów rozwojowych i adaptacji AI
 Źródło: opracowanie własne w pakiecie GeoDa.




Ryc. 3. Analiza przestrzennego zróżnicowania PKB per capita

Źródło: opracowanie własne w pakiecie GeoDa.

wysokich wartości w regionach Europy Zachodniej i Północnej, przy jednoczesnym utrzymywaniu się niższych poziomów w Europie Środkowo-Wschodniej oraz części Południa. Wyniki globalnej analizy autokorelacji przestrzennej potwierdzają istnienie istotnych zależności przestrzennych – wartość statystyki Morana na poziomie około $I \approx 0,32$ wskazuje na umiarkowaną dodatnią autokorelację. Oznacza to, że regiony o podobnym poziomie PKB per capita mają tendencję do częściowego grupowania się, jednak siła tego zjawiska jest wyraźnie słabsza niż w odniesieniu do niektórych nakładów rozwojowych. Może to świadczyć o tym, że poziom rozwoju gospodarczego jest w pewnym stopniu uwarunkowany przestrzennie, jednak większą rolę niż w przypadku nowych technologii odgrywają zróżnicowane czynniki krajowe i regionalne, co przekłada się na bardziej rozproszony i mniej jednorodny wzorec przestrzenny.

Wszystkie analizowane zmienne wskazują na wyraźną polaryzację przestrzenną pomiędzy wysoko rozwiniętymi obszarami metropolitalnymi Europy, takimi jak Warszawa, Berlin, Paryż czy Wilno, a regionami o niższym poziomie urbanizacji. Jednocześnie dla wszystkich nakładów i efektów zaobserwowano występowanie klastrow niskich wartości, koncentrujących się głównie w Europie Środkowo-Wschodniej. Istnienie silnych i niejednorodnych wzorców przestrzennych dla zmiennych ICT, AI, nakładów rozwojowych oraz wyników gospodarczych regionów uzasadnia wykorzystanie przestrzennej analizy efektywności.

Współczynnik efektywności wyznaczony za pomocą modelu SDEA-INI wskazuje, że jedynie 14 regionów NUTS 2 (5,9% badanych jednostek) osiągnęło pełną efektywność ($\theta = 1$), wyznaczając granicę efektywności i stanowiąc wzorce dla pozostałych regionów (por. ryc. 4). Wśród regionów efektywnych szczególnie



Ryc. 4. Analiza przestrzennego zróżnicowania wyników modelu SDEA-INI
Źródło: opracowanie własne w pakiecie GeoDa.

wyróżnia się Rumunia, w której aż pięć z ośmiu regionów NUTS 2 osiągnęło pełną efektywność: Nord-Est (RO21), Sud-Est (RO22), Sud-Muntenia (RO31), Sud-Vest Oltenia (RO41) oraz București-Ilfov (RO32). Pozostałe benchmarki obejmują dwa regiony Bułgarii – Severozapaden (BG31) i Yugoiztochen (BG34), a także Luksemburg oraz pojedyncze regiony w Polsce (mazowiecki regionalny – PL92), Portugalii (Algarve – PT15), Włoszech (Provincia Autonoma di Bolzano/Bozen – ITH1) oraz regiony wyspiarskie w Grecji (Notio Aigaio (South Aegean) – EL42), Hiszpanii (Illes Balears – ES53) i Francji (Corse – FRM0).

Znaczne zróżnicowanie efektywności potwierdza rozkład współczynników θ . Najniższą wartość efektywności ($\theta = 0,36$) odnotowano w regionie Hainaut (BE32) oraz w Estonii. Połowa regionów NUTS 2 w Europie nie przekroczyła poziomu efektywności wynoszącego 0,57, przy czym pierwszy kwartył rozkładu wyniósł 0,48, a trzeci 0,69. Na szczególną uwagę zasługuje skrajnie spolaryzowany północno-wschodni obszar Bułgarii – NUTS 1 (BG3), w którym jednocześnie zlokalizowane są dwa wzorcowe regiony oraz region o minimalnej efektywności.

Należy zauważyć, że w modelach DEA efektywność ma charakter względny i odzwierciedla relację pomiędzy osiąganym efektem a poziomem wykorzystanych nakładów. Oznacza to, że niski poziom zasobów cyfrowo-innowacyjnych w połączeniu z względnie wysokim regionalnym PKB może skutkować wysoką efektywnością, czego przykładem mogą być niektóre regiony Rumunii i Bułgarii. Analogicznie wysoki poziom produkcji w regionie, przy jednocześnie wysokich nakładach, często przekłada się na niską efektywność cyfrowo-innowacyjną, co obserwuje się m.in. w regionach Europy Zachodniej i Północnej. Ponadto wysokie PKB regionu może wynikać z czynników niezwiązanych bezpośrednio z ICT,

AI czy działalnością B+R, takich jak struktura sektorowa, funkcje metropolitalne, koncentracja siedzib korporacji, specjalizacja finansowa, turystyka czy renty lokalizacyjne. Z kolei wysoki poziom innowacyjności nie musi przekładać się na wysokie PKB per capita, jeśli jej efekty nie zostały jeszcze skapitalizowane lub są ograniczane przez słabszą strukturę gospodarczą. Potwierdza to zasadność późniejszego porównania wyników modelu SDEA-INI z klasyfikacją RIS, która opisuje poziom innowacyjności regionów, a nie efektywność wykorzystania ich zasobów.

Przestrzenne wzorce efektywności cyfrowo-innowacyjnej gospodarek regionalnych wykazują istotną dodatnią autokorelację przestrzenną ($I \approx 0,38$). Na poziomie lokalnym klastry wysokiej efektywności – „wysokie-wysokie” – znajdują się przede wszystkim w Rumunii i Bułgarii, a także w Polsce centralnej oraz w regionach na pograniczu Austrii i Włoch. Z kolei klastry niskiej efektywności – „niskie-niskie” – obejmują znaczną część Finlandii oraz fragmenty Szwecji, Niemiec, Francji i krajów Beneluksu, a także regiony zlokalizowane na pograniczu Węgier, Chorwacji i Słowacji oraz na Łotwie.


W celu ułatwienia interpretacji wyników opracowano klasyfikację regionów wzorowaną na metodologii RIS. Ocenia ona regionalne systemy innowacji na podstawie syntetycznego indeksu innowacyjności (ang. *Regional Innovation Index*), klasyfikując regiony do czterech grup: *Innovation Leaders*, *Strong Innovators*, *Moderate Innovators* oraz *Emerging Innovators*. Warto zauważyć, że punktem odniesienia jest średni poziom innowacyjności Unii Europejskiej (UE), zatem, podobnie jak w naszym modelu, ranking RIS ma charakter relatywny (RIS 2025).

W niniejszym badaniu klasyfikację efektywności cyfrowo-innowacyjnej regionów – RDIEC – oparto na wartościach wskaźnika efektywności uzyskanych z modelu SDEA-INI. Ze względu na specyfikę metod DEA regiony osiągające pełną efektywność ($\theta = 1$) tworzą odrębną kategorię liderów efektywności (ang. *Efficiency Leaders*). Pozostałe regiony przypisano do klas silnych performerów (ang. *Strong Performers*), umiarkowanych performerów (ang. *Moderate Performers*) oraz słabych performerów (ang. *Lower Performers*) w zależności od poziomu uzyskanej efektywności. Podejście takie zachowuje logikę klasyfikacji RIS, jednocześnie uwzględniając specyfikę analiz efektywności, w których szczególną rolę odgrywają jednostki wyznaczające granicę efektywności. Zasadę klasyfikacji oraz jej nomenklaturę w języku polskim i angielskim zaprezentowano w tabeli 2, zaś rycina 5 zawiera wizualizację rozkładu przestrzennego RDIEC zestawioną z wynikami RIS.

Tabela 2. Regionalna klasyfikacja efektywności cyfrowo-innowacyjnej – RDIEC

Nazwa polska (nazwa angielska)	Zakres efektywności θ
Liderzy efektywności (ang. <i>Efficiency Leaders</i>)	$\theta = 1,00$
Silni performerzy (ang. <i>Strong Performers</i>)	$0,70 \leq \theta < 1,00$
Umiarkowani performerzy (ang. <i>Moderate Performers</i>)	$0,50 \leq \theta < 0,70$
Słabi performerzy (ang. <i>Lower Performers</i>)	$\theta < 0,50$

Źródło: opracowania własne.



Ryc. 5. Klasyfikacja innowacyjności (RIS) i efektywności cyfrowo-innowacyjnej (RDIEC) w regionach NUTS 2, 2025

Źródło: RDIEC – opracowania własne w GeoDa na podstawie wyników SDEA-INI; RIS zaczerpnięty z RIS (2025).

Ranking RIS pokazuje, że w 2025 r. najwyższe poziomy innowacyjności koncentrowały się przede wszystkim w regionach Szwecji, Danii, Norwegii, Finlandii, Holandii, Niemiec, Belgii i Austrii. Regiony te charakteryzują się wysokimi nakładami na działalność badawczo-rozwojową, rozwiniętym sektorem wdrożeniowym oraz silnymi powiązaniem pomiędzy nauką i biznesem. Z kolei najniższe wartości indeksu RIS odnotowano głównie w regionach Europy Centralnej i Wschodniej, gdzie poziom aktywności badawczo-rozwojowej, cyfryzacji przedsiębiorstw oraz komercjalizacji wiedzy pozostaje relatywnie niski w porównaniu ze średnią UE (RIS 2025; ryc. 5).

Klasyfikacja regionów według efektywności wykorzystania narzędzi ICT, AI oraz nakładów rozwojowych w kreowaniu wyników gospodarczych wskazuje, że wysoki poziom innowacyjności nie zawsze przekłada się na wysoką efektywność wykorzystania dostępnych zasobów. Ranking RDIEC, oparty na wynikach modelu SDEA-INI, ujawnia, że największą liczbę regionów wzorcowych posiada Rumunia, a pełną efektywność osiągnęły również pojedyncze regiony Bułgarii, Polski, Portugalii, Włoch, Grecji, Hiszpanii, Francji oraz Luksemburg. Na uwagę zasługuje fakt, że wśród liderów występują regiony peryferyjne i wyspiarskie, takie jak South Aegean, Illes Balears czy Corse. Zastosowany model niestety nie rozstrzyga, czy efektywność ta wynika z konieczności pokonania ograniczeń wynikających z izolacji, czy też brak sąsiadów pozwala na niepodzielne wykorzystanie własnych zasobów.

Silni performerzy efektywności cyfrowo-innowacyjnej ($\theta \geq 0,70$) często sąsiadują z regionami wzorcowymi, co jest szczególnie widoczne na Bałkanach, w Polsce oraz Portugalii. Może to wskazywać na występowanie przestrzennych efektów dyfuzji wiedzy, transferu dobrych praktyk oraz przepływu know-how pomiędzy

regionami. Regiony należące do grupy słabych performerów ($\theta < 0,50$) tworzą wyraźne klastry przestrzenne, obejmujące m.in. znaczną część Skandynawii, państw bałtyckich oraz wybrane obszary Europy Środkowej. Wiele z nich znajduje się w sąsiedztwie liderów i silnych performerów. Oznacza to, że sama bliskość regionów o wysokiej efektywności nie gwarantuje osiągnięcia podobnych rezultatów, a zdolność absorpcji wiedzy i wykorzystania dostępnych zasobów pozostaje silnie zróżnicowana przestrzennie.

Porównanie klasyfikacji RIS i RDIEC wskazuje, że poziom innowacyjności oraz efektywność cyfrowo-innowacyjna opisują komplementarne aspekty rozwoju technologicznego. Podczas gdy RIS identyfikuje regiony dysponujące największym zasobem kapitału innowacyjnego, infrastruktury badawczej i aktywności innowacyjnej, RDIEC ukazuje, w jakim stopniu zasoby te są skutecznie przekształcane w wyniki gospodarcze. W konsekwencji regiony uznawane za liderów innowacyjności nie zawsze należą do najbardziej efektywnych i odwrotnie, choć niektóre regiony w Austrii i krajach Beneluksu charakteryzują się zarówno wysoką innowacyjnością, jak i efektywnością cyfrowo-innowacyjną. Oznacza to, że regiony te nie tylko dysponują znacznym potencjałem innowacyjnym, lecz także skutecznie przekształcają go w rezultaty gospodarcze.

Wnioski

Badanie wykazało, że efektywność wykorzystania zasobów związanych z cyfryzacją i innowacyjnością istotnie różni się pomiędzy regionami Europy. Zastosowanie modelu SDEA-INI pozwoliło ocenić, w jakim stopniu funkcjonowanie przedsiębiorstw wykorzystujących technologie ICT, rozwiązania chmurowe, narzędzia sztucznej inteligencji, analitykę danych oraz zatrudnienie w sektorach wysokich technologii przekłada się na wyniki gospodarcze regionów. Rezultaty badania wskazują, że jedynie niewielka grupa regionów osiąga pełną efektywność, a większość jednostek wykorzystuje dostępne zasoby tylko częściowo.

Istotnym efektem badania jest również identyfikacja silnych wzorców przestrzennych efektywności cyfrowo-innowacyjnej. Regiony o podobnym poziomie efektywności przejawiają tendencję do grupowania się przestrzennego, co może wskazywać na znaczenie transferu wiedzy, efektów uczenia się oraz współpracy międzyregionalnej. Jednocześnie występowanie zarówno regionów bardzo efektywnych, jak i bardzo nieefektywnych w obrębie tych samych państw świadczy o dużej roli regionalnych uwarunkowań instytucjonalnych, organizacyjnych i gospodarczych. Wynika z tego, że o sukcesie transformacji cyfrowej decyduje nie tylko poziom nakładów, ale też zdolność regionów do ich absorpcji i produktywnego wykorzystania. Ponadto sąsiedztwo regionów wysoko rozwiniętych nie gwarantuje automatycznego osiągania wysokiej efektywności. Uzyskane rezultaty są zgodne z wcześniejszymi badaniami wskazującymi, że na efektywność cyfrowo-innowacyjną regionów mogą oddziaływać m.in.: jakość administracji publicznej, zdolność instytucji regionalnych do wspierania innowacji, poziom kompetencji cyfrowych mieszkańców, jakość systemu edukacji, współpraca pomiędzy

uczelniami i przedsiębiorstwami oraz struktura gospodarcza regionu (Mosconi, D'Ingiullo 2023, Aparicio-Pérez i in. 2025, RIS 2025).

Analiza ujawniła również wyraźne różnice pomiędzy poziomem innowacyjności regionów a efektywnością wykorzystania zasobów cyfrowo-innowacyjnych. Oznacza to, że skala dostępnych zasobów nie jest jedynym czynnikiem sukcesu, ponieważ tak samo istotna jest zdolność do ich wykorzystania. Uzyskane wyniki mają zatem istotne implikacje dla polityki regionalnej. W regionach o niskiej efektywności działania rozwojowe nie powinny ograniczać się wyłącznie do zwiększania nakładów finansowych na ICT lub sztuczną inteligencję. Znacznie istotniejsza może okazać się poprawa warunków umożliwiających efektywne wykorzystanie tych technologii. Obejmuje to przede wszystkim rozwój kompetencji cyfrowych pracowników, wsparcie procesów transformacji cyfrowej przedsiębiorstw, wzmacnianie współpracy pomiędzy sektorem nauki i biznesem oraz rozwój instytucji pośredniczących w transferze technologii. Szczególnie w przypadku regionów charakteryzujących się niską adaptacją sztucznej inteligencji zasadne wydaje się tworzenie regionalnych centrów kompetencji AI, wspieranie projektów demonstracyjnych oraz rozwój programów szkoleniowych dla przedsiębiorstw sektora MŚP. Ważne może być również zwiększanie dostępności infrastruktury cyfrowej, usług chmurowych oraz narzędzi analityki danych, które stanowią podstawę skutecznego wdrażania rozwiązań opartych na sztucznej inteligencji.

Z kolei w regionach osiągających wysoką efektywność polityka publiczna powinna koncentrować się na utrzymaniu przewag konkurencyjnych poprzez dalsze wzmacnianie ekosystemów innowacji, wspieranie specjalizacji technologicznych oraz rozwój zaawansowanych klastrów cyfrowych. Szczególnie istotne może być stymulowanie współpracy międzyregionalnej, umożliwiającej transfer wiedzy i dobrych praktyk do regionów słabiej rozwiniętych.

Badanie potwierdza również, że polityka cyfrowa nie powinna być projektowana wyłącznie na poziomie krajowym. Znaczne zróżnicowanie efektywności pomiędzy regionami tego samego państwa wskazuje na potrzebę większego uwzględniania specyfiki regionalnej przy projektowaniu instrumentów wsparcia transformacji cyfrowej. Rozwiązania skuteczne w wysoko rozwiniętych metropoliach technologicznych mogą nie przynosić podobnych efektów w regionach peryferyjnych, które borykają się z niedoborem kapitału ludzkiego, słabszą bazą przedsiębiorstw innowacyjnych lub ograniczoną zdolnością absorpcji nowych technologii.

Powyższe wnioski znajdują potwierdzenie w zaleceniach OECD, zgodnie z którymi wzrost nakładów na działalność badawczo-rozwojową nie gwarantuje poprawy wyników innowacyjnych regionów. Warunkiem skutecznego wykorzystania tych zasobów jest równoczesny rozwój zdolności absorpcyjnych, efektywnych mechanizmów transferu i dyfuzji wiedzy, współpracy międzysektorowej i międzyregionalnej oraz lokalnych ekosystemów innowacji (OECD 2011, 2020, 2025). Również inne badania potwierdzają, że przewaga konkurencyjna nie wynika wyłącznie z poziomu inwestycji w technologie cyfrowe i sztuczną inteligencję, lecz przede wszystkim ze zdolności do ich integracji z procesami biznesowymi (Guellec, Paunov 2018).

Badanie cechuje się kilkoma ograniczeniami wynikającymi zwłaszcza z dostępności porównywalnych danych regionalnych oraz specyfiki zastosowanej metody. Po pierwsze, wykorzystany wskaźnik adaptacji AI odzwierciedla zakres wykorzystania tej technologii w przedsiębiorstwach, nie pozwalając jednak na ocenę intensywności ani stopnia zaawansowania jej zastosowań, co wynika z ograniczonej dostępności bardziej szczegółowych danych na poziomie regionalnym. Po drugie, jako efekt gospodarczy przyjęto PKB per capita, ponieważ dla analizowanych regionów NUTS 2 brakuje aktualnych i porównywalnych danych dotyczących bezpośrednich efektów działalności innowacyjnej, takich jak patenty Europejskiego Urzędu Patentowego (EPO) czy regionalna sprzedaż innowacyjnych produktów (Kopczewska, Piotrowska 2026). Po trzecie, uzyskane wyniki należy interpretować jako względną efektywność analizowanych regionów w ramach przyjętej specyfikacji modelu, zgodnie z podejściem DEA.

W przyszłych badaniach warto rozszerzyć analizę o dynamiczną ocenę zmian efektywności w czasie oraz uwzględnić dodatkowe mierniki rezultatów, takie jak produktywność pracy, aktywność patentowa, poziom innowacyjności przedsiębiorstw czy jakość zatrudnienia. Pozwoliłoby to pełniej ocenić długookresowe efekty wykorzystania technologii cyfrowych i sztucznej inteligencji w rozwoju regionalnym.

Konflikt interesów/wkład autorek

Autorki deklarują brak konfliktu interesów. Oświadczają, że tekst artykułu jest w całości ich dziełem. Podział pracy przy artykule wyglądał następująco:

- konceptualizacja: AO, AŻ,
- metodologia: AO, AŻ,
- organizacja badań: AO, AŻ,
- analiza formalna: AO, AŻ,
- pisanie: AO, AŻ.

Literatura / References

- Abdeljawad I., Nour A.I., Utt A.S. 2023. Impact of Information and Communication Technology (ICT) on Labor Productivity of Palestinian Manufacturing Firms. [W:] A. Hannoon, A. Mahmood (red.), *Artificial Intelligence, Internet of Things, and Society 5.0. Studies in Computational Intelligence*, 1113. Springer, Cham. https://doi.org/10.1007/978-3-031-43300-9_29
- Abid I. 2025. Energy, Finance, and Innovation in High-Income Countries: Short- and Long-Run Evidence from the ARDL-ECM Framework. *Annals of Financial Economics*, 20(3). <https://doi.org/10.1142/S2010495225500174>
- Aiginger K., Falk M. 2005. Explaining Differences in Economic Growth among OECD Countries. *Empirica*, 32: 19–43. <https://doi.org/10.1007/s10663-005-1977-7>
- Amiri E., Babazadeh Sangar A.B. 2023. Assessing the ICT Development in Iranian Cities: The Strategy to Accelerate Digital Advancement. *Technological Forecasting and Social Change*, 197: 122904. <https://doi.org/10.1016/j.techfore.2023.122904>
- Anselin L. 1995. Local Indicators of Spatial Association – LISA. *Geographical Analysis*, 27: 93–115.

- Aparicio-Pérez D., Balaguer-Coll M.T., Peiró-Palomino J., Tortosa-Ausina E. 2025. On the Relative Contributions of National and Regional Institutions to Economic Development. *Journal of Regional Science*, 65: 1118–1136. <https://doi.org/10.1111/jors.12776>
- Banday T.P., Erdem E. 2024. ICT and Declining Labor Productivity in OECD. *SN Business & Economics*, 4: 33. <https://doi.org/10.1007/s43546-024-00626-5>
- Bravo-Ortega C., García Marín Á. 2011. R&D and Productivity: A Two Way Avenue? *World Development*, 39(7): 1090–1107. <https://doi.org/10.1016/j.worlddev.2010.11.006>
- Chakraborty S., Panda R. 2026. Effect of Artificial Intelligence (AI) on GDP Growth of India in 2022: An Analysis. [W:] *Artificial Intelligence in Business and Society: Global Insights*, s. 37–48.
- Charnes A., Cooper W.W., Rhodes E. 1978. Measuring the Efficiency of Decision-Making Units. *European Journal of Operational Research*, 2: 429–444.
- Coronel V.J., Díaz-Roldán C. 2025. Economic Growth in the European Union: Exploring the Role of Innovation and Gender. *Economics and Business Review*, 11(2): 91–117. <https://doi.org/10.18559/ebr.2025.2.1917>
- Criveanu M.M. 2026. The Impact of Digital Technology on E-Commerce and Sustainable Performance in the EU. *Economies*, 14(1): 5. <https://doi.org/10.3390/economies14010005>
- Drago C., Costantiello A., Savorgnan M., Leogrande A. 2025. Macroeconomic and Labor Market Drivers of AI Adoption in Europe: A Machine Learning and Panel Data Approach. *Economies*, 13(8): 226. <https://doi.org/10.3390/economies13080226>
- Falk M. 2007. R&D Spending in the High-Tech Sector and Economic Growth. *Research in Economics*, 61(3): 140–147. <https://doi.org/10.1016/j.rie.2007.05.002>
- Fu Y., Chen Y., Zhang Y., Wang M., Yu Y. 2026. Corporate Productivity Transformation under the Innovation Paradigm: The Role and Impact of Artificial Intelligence. *Technology in Society*, 84: 103141. <https://doi.org/10.1016/j.techsoc.2025.103141>
- Guellec D., Paunov C. 2018. Innovation Policies in the Digital Age. OECD Science, Technology and Industry Policy Papers, 59. OECD Publishing, Paris. <https://doi.org/10.1787/eadd1094-en>
- Ilham M., Natsir M., Gamsir, Lapipi, Saili T., Balaka M.Y., Rostin, Rahim M., Saenong Z., Alwi S., Nusantara A.W., Hasddin. 2025. The Role of Internet Penetration in Agricultural Development, Economic Growth and Development Index. *Journal of Global Innovations in Agricultural Sciences*, 13: 523–537. <https://doi.org/10.22194/JGIAS/25.1660>
- Kachunga B., Nyangarika A., Mikhaylov A. i in. 2026. Economic Drivers of GDP per Capita Growth in Tanzania: The Role of Start-Up Costs, Industrial Employment, and Technological Cooperation. *Quality & Quantity*, 60: 7613–7629. <https://doi.org/10.1007/s11135-026-02600-9>
- Kayalvili S., Sundaramoorthy J., Meda R., Bhavanam S.N., Rao K.S. i in. 2025. Cloud-Integrated Enterprise Resource Planning for Sustainable Business Growth. [W:] *2025 IEEE 3rd Global Conference on Wireless Computing and Networking (GCWCN)*. IEEE, Lonawala, Maharashtra, India, s. 1–7. <https://doi.org/10.1109/GCWCN66157.2025.11448351>
- Kharod S., Kaur J. 2026. Integrating AI in Industry: Automation and Innovation. [W:] *AI Modernisation Techniques for Contemporary Trends*, s. 44–59. <https://doi.org/10.1201/9781003592204-4>
- Kopczewska K., Piotrowska K. 2026. Has the East met the West? Spatial Dynamics of Innovation in Europe. *Netw Spat Econ*. <https://doi.org/10.1007/s11067-026-09747-w>
- Li Z., Huang Z., Zhang S. 2026. Regional Disparities in Artificial Intelligence Development and Green Economic Efficiency Performance Under Its Embedding: Empirical Evidence from China. *Sustainability*, 18(2): 884. <https://doi.org/10.3390/su18020884>
- Lin L. 2006. The Influences of R&D Expenditures on Knowledge-Based Economy in Taiwan. [W:] B. Gabrys, R.J. Howlett, L.C. Jain (red.), *Knowledge-Based Intelligent Information and Engineering Systems. Lecture Notes in Computer Science*, 4253. Springer, Berlin–Heidelberg. https://doi.org/10.1007/11893011_118
- Łącka I., Brzezicki Ł. 2025. Evaluating the efficiency of regional innovation systems in Europe: DEA approach. *Social Inequalities and Economic Growth*, 81: 123–151. <https://doi.org/10.15584/nsawg.2025.1.8>
- Mitrović D. 2020. Measuring the Efficiency of Digital Convergence. *Economics Letters*, 188: 108982. <https://doi.org/10.1016/j.econlet.2020.108982>
- Mosconi F., D'Ingiullo D. 2023. Institutional quality and innovation: evidence from Emilia-Romagna. *Economics of Innovation and New Technology*, 32(2): 165–197. <https://doi.org/10.1080/10438599.2021.1893140>

- OECD. 2011. Regions and Innovation Policy. OECD Reviews of Regional Innovation. OECD Publishing, Paris. <https://doi.org/10.1787/9789264097803-en>
- OECD. 2020. Broad-based Innovation Policy for All Regions and Cities. OECD Regional Development Studies. OECD Publishing, Paris. <https://doi.org/10.1787/299731d2-en>
- OECD. 2025. OECD Science, Technology and Innovation Outlook 2025: Driving Change in a Shifting Landscape. OECD Publishing, Paris. <https://doi.org/10.1787/5fe57b90-en>
- Olejnik A., Zółtaszek A., Olejnik J. 2021. Spatial Solution to Measure Regional Efficiency – Introducing Spatial Data Envelopment Analysis. *Ekonomika Regiona*, 17(4): 1166–1180.
- Olejnik J., Zółtaszek A., Olejnik A. 2026. Spatial DEA with Independent Neighbours' Inputs: Healthcare Efficiency Patterns in Europe. *Spatial Economic Analysis*, 21(2): 187–204. <https://doi.org/10.1080/17421772.2025.2600420>
- Oliinyk A., Melnyk T., Kovtoniuk K., Huliaieva L., Molchanova E., Tkachenko I. 2024. ICT Investment Impact on Economic Growth: Comparing Developing and Advanced Economies. [W:] 2024 14th International Conference on Advanced Computer Information Technologies (ACIT). IEEE, Ceske Budejovice, s. 197–202. <https://doi.org/10.1109/ACIT62333.2024.10712512>
- Pan Y. 2025. E-commerce Logistics Big Data. [W:] Z. Qin, Q. Shuai (red.), *Handbook of E-commerce in China*. Springer, Singapore. https://doi.org/10.1007/978-981-96-7629-3_25
- Pažun B., Langović Z., Stojanović V.S. i in. 2025. The Influence of Information and Communication Technology on Economic Growth in Europe. *Journal of the Knowledge Economy*, 16: 17840–17868. <https://doi.org/10.1007/s13132-024-02576-7>
- Premavathi T., Jain R., Parmar K., Palaniappan D. 2025. Artificial Intelligence as a Catalyst for Economic Development. [W:] *Driving Socio-Economic Growth With AI and Blockchain*, s. 205–228. <https://doi.org/10.4018/979-8-3693-8664-4.ch009>
- Ramzi S., Afonso A., Ayadi M. 2016. Assessment of efficiency in basic and secondary education in Tunisia: A regional analysis. *International Journal of Educational Development*, 51: 62–76. <https://doi.org/10.1016/j.ijedudev.2016.08.003>
- Regional Innovation Scoreboard 2025. 2025. European Commission, Brussels.
- Song X., Han W. 2023. Innovative AI Regional Economic Development Driven by Information System Innovation: Opportunities and Challenges – A Boosting Factor from Digitalization, Business Intelligence Analytics. *Journal of Information Systems Engineering and Management*, 8(4): 23783. <https://doi.org/10.55267/iadt.07.14035>
- Tripathi M., Inani S.K. 2020. Does Information and Communications Technology Affect Economic Growth? Empirical Evidence from SAARC Countries. *Information Technology for Development*, 26(4): 773–787. <https://doi.org/10.1080/02681102.2020.1785827>
- Valero A., van Reenen J. 2019. The Economic Impact of Universities: Evidence from Across the Globe. *Economics of Education Review*, 68: 53–67. <https://doi.org/10.1016/j.econedurev.2018.09.001>
- Wang L., Sarker P., Alam K., Sumon S. 2021. Artificial Intelligence and Economic Growth: A Theoretical Framework. *Scientific Annals of Economics and Business*, 68(4): 421–443. <https://doi.org/10.47743/saeb-2021-0027>. [artykuł wycofany].
- Wang S., Liu J., Xiao B. i in. 2026. From Digital Circulation to Green Growth: The Mediating Role of Digital Technology Innovation in E-commerce's Impact on Urban Green Productivity. *Electronic Commerce Research*. <https://doi.org/10.1007/s10660-026-10096-6>
- Yu W., Du B., Guo X. i in. 2025. Total Factor Productivity in Chinese Manufacturing Firms: The Role of E-commerce Adoption. *Electronic Commerce Research*, 25: 1005–1031. <https://doi.org/10.1007/s10660-023-09711-7>
- Zac C.H., Rana M.E., Jayabalan M., Hameed V.A. 2026. Leveraging Cloud Computing for Enhanced Artificial Intelligence and Machine Learning: A Comprehensive Analysis of Service Models, Deployment Strategies, and Provider Offerings. [W:] V. Bhateja, S.M. Biju, S.K. Udgate (red.), *Information System Design: AI and ML Applications*. Lecture Notes in Networks and Systems, 1565. Springer, Singapore. https://doi.org/10.1007/978-981-95-0375-9_42

Spatial assessment of innovation resource utilization efficiency in regional economies: An SDEA-INI approach integrating ICT and AI

Abstract: The aim of this article is to assess the digital-innovation efficiency of European NUTS 2 regions in 2025, taking into account inputs related to information and communication technologies (ICT), artificial intelligence (AI), research and development (R&D), and employment in high-technology sectors. The study applies the SDEA-INI model (Spatial Data Envelopment Analysis with Independent Neighbour Inputs), which incorporates spatial dependencies and the non-controllability of spatially related inputs into the efficiency assessment framework. Based on the model results, the Regional Digital-Innovation Efficiency Classification (RDIEC) was developed to identify regions that most effectively transform digital and innovation-related resources into economic outcomes. Furthermore, the RDIEC results were compared with the European Commission's Regional Innovation Scoreboard (RIS) classification, allowing an assessment of the relationship between the level of regional innovativeness and the efficiency with which innovation potential is utilised. The findings reveal substantial spatial disparities in digital-innovation efficiency across European regions. Only 6% of the analysed regions achieve full efficiency, indicating that high levels of digital and innovation-related inputs do not automatically translate into comparable economic outcomes. Moreover, the coexistence of highly inefficient regions in close proximity to digital-innovation leaders and strong performers demonstrates that spatial proximity alone does not guarantee the diffusion of benefits. The results highlight that regions differ considerably in their capacity to absorb knowledge, leverage available resources, and translate digital capabilities into measurable economic outcomes. These findings emphasise the importance of considering local institutional, organisational, and economic conditions when analysing the effectiveness of digital transformation and innovation-driven regional development.

Keywords: digital-innovation efficiency, artificial intelligence (AI), information and communication technologies (ICT), Spatial Data Envelopment Analysis with Independent Neighbour Inputs (SDEA-INI), regional development

Data przekazania tekstu: 17.06.2026; **data zaakceptowania tekstu:** 20.07.2026.

Article submitted: 17.06.2026; **article accepted:** 20.07.2026.