



DOI:10.18276/sip.2016.45/2-22

Paweł Kobus*

Szkoła Główna Gospodarstwa Wiejskiego w Warszawie

DETERMINANTY POZIOMU UBEZPIECZEŃ ROLNICZYCH

Streszczenie

Pomimo określonego ustawą obowiązku ubezpieczenia co najmniej 50% powierzchni upraw zaledwie około 11% rolników wykupuje ubezpieczenia upraw. W celu określenia determinant poziomu ubezpieczeń upraw w rolnictwie w opracowaniu analizowano wpływ zmiennych charakteryzujących rolnika: płci, wieku, wykształcenia, deklarowanego stosunku do ryzyka oraz zmiennych charakteryzujących gospodarstwo: regionu kraju, typu produkcyjnego, wielkości ekonomicznej, wystąpienia znaczących szkód w przeszłości. Na podstawie próby 590 gospodarstw przy użyciu regresji logistycznej stwierdzono pozytywny wpływ wielkości ekonomicznej gospodarstwa, przynależności do roślinnego typu produkcji, lokalizacji w regionie 790 (wielkopolskie, dolnośląskie, kujawsko-pomorskie i opolskie) oraz wystąpienia w przeszłości szkód w uprawach.

Słowa kluczowe: ubezpieczenia upraw, losowanie warstwowe, regresja logitowa

Wstęp

Powszechnie wskazuje się na ubezpieczenia jako podstawowy sposób zabezpieczenia się przed ryzykiem wystąpienia szkód spowodowanych przez powódź, grad, suszę, ujemne skutki przezimowania oraz przymrozki wiosenne. Co więcej, zgodnie z ustawą z 7 lipca 2005 roku o ubezpieczeniach upraw rolnych i zwierząt gospodarskich (Dz.U. nr 150, poz. 1249, z późn. zm.) ubezpieczenie przez rolników

* Adres e-mail: pawel_kobus@sggw.pl.

co najmniej 50% powierzchni upraw jest obligatoryjne. Jednak w praktyce większość rolników nie stosuje się do tego przepisu. Według GUS (2014) w 2013 roku łączna powierzchnia użytków rolnych w Polsce to 14,6 mln ha, a liczba gospodarstw rolnych o powierzchni użytków rolnych powyżej 1 ha wynosiła 1394,6 tys. Jednocześnie zgodnie z raportem NIK (2014) w roku 2013 zawarto 151,1 tys. umów ubezpieczenia upraw rolnych obejmujących łącznie powierzchnię 3398,8 tys. ha upraw rolnych. To oznacza, że ubezpieczenie upraw zdecydowało się wykupić 10,8% rolników i dotyczyło to łącznie 23,28% użytków rolnych lub 31,76%, jeżeli odniesiemy to do powierzchni zasiewów i upraw trwałych. Biorąc pod uwagę obligatoryjność ubezpieczenia upraw, 10,8% rolników zawierających umowy ubezpieczenia upraw musi zastanawiać. Według GUS (2014) 44,2% gospodarstw większość dochodów czerpie z działalności pozarolniczej, można więc uznać, że w gospodarstwach tych ewentualne obniżenie plonów upraw nie ma znaczącego wpływu na poziom dochodów i tym samym skłonność do ubezpieczania upraw jest ograniczona. Jednak nawet przyjęcie za podstawę tylko tych gospodarstw, które czerpią większość dochodów z działalności rolniczej, oznacza niecałe 20% ubezpieczonych gospodarstw. W konsekwencji pytanie o czynniki wpływające na podjęcie decyzji o ubezpieczeniu gospodarstw pozostaje otwarte.

W pracy (Stempel, 2013) i w rozdziale 8 monografii (Wicka, 2013), zajmujących się tematyką determinant poziomu ubezpieczeń rolniczych w Polsce, wskazywano na następujące czynniki: wielkość gospodarstwa, wykształcenie, udział produkcji roślinnej w sprzedaży ogółem, dochód brutto, wykształcenia rolników oraz staż w prowadzeniu gospodarstwa. W obydwu opracowaniach stwierdzono, że wszystkie rozpatrywane czynniki wpływają na poziom ubezpieczeń upraw. Niestety w aspekcie metodycznym obydwie prace są obciążone pewnymi wadami.

W pracy (Stempel, 2013) ograniczono się do prostego zestawienia udziału ubezpieczeń upraw na poszczególnych poziomach czynników i wskazano, że na wyższych poziomach rozpatrywanych czynników, to znaczy powierzchni upraw, wykształcenia rolników oraz stażu w prowadzeniu gospodarstwa, większy odsetek rolników wykupuje ubezpieczenia upraw. Nie podjęto jednak próby oceny istotności tych efektów. Natomiast w pracy (Wicka, 2013) przyjęto, że cechy objaśniające mają charakter ciągły i oddzielnie dla każdej zmiennej objaśniającej oszacowano modele logitowe, stwierdzając istotność wpływu powierzchni użytków rolnych, udziału produkcji roślinnej w sprzedaży ogółem oraz dochodu brutto na prawdopodobieństwo ubezpieczenia upraw.

Wadą stosowania wyłącznie modeli z jedną zmienną objaśniającą jest fakt uwikłania w ocenę efektu badanej zmiennej wszystkich zmiennych nieujętych w badaniu i choć oczywiście model zawsze pozostaje uproszczonym opisem rzeczywistości, to ujęcie w modelu większej liczby zmiennych objaśniających zwiększa precyzję oceny „czystego” efektu poszczególnych zmiennych.

W obydwu pracach korzystano z losowania warstwowego w doborze próby, jednak w dalszej analizie nie było to uwzględnione. Z uwagi na losowanie warstwowe z zachowaniem proporcjonalnych liczebności w warstwach oceny punktowe udziału gospodarstw z wykupionym ubezpieczeniem upraw oszacowane w pracy Stempla (2013) nie budzą większych wątpliwości. Natomiast w pracy (Wicka, 2013) korzystano z próby Polskiego FADN, gdzie liczebności w warstwach wyznacza się metodą optymalnej alokacji Neymana, która skutkuje dodatkowym zmniejszeniem wariancji oceny średnich wartości za cenę nieproporcjonalnych liczebności w warstwach. Dlatego pomimo zastosowania w (Wicka, 2013) testów istotności uzyskane wyniki nie są wiarygodne.


Celem niniejszego artykułu jest określenie czynników wpływających (skorelowanych) na decyzję ubezpieczenia upraw przez rolnika, z naciskiem na poprawną metodykę.

1. Pole obserwacji i dobór próby

Jak wspomniano we wstępie, liczba gospodarstw rolnych o powierzchni użytków rolnych powyżej 1 ha wynosiła w roku 2013 1394,6 tys., jednak w niniejszym opracowaniu ograniczono się do gospodarstw rolnych charakteryzujących się standardową produkcją (Standard Output) co najmniej 4000 euro, których jest 730,9 tys. Łączna wartości produkcji (SO) tych gospodarstw stanowi 93% produkcji wszystkich gospodarstw rolnych w Polsce.

W celu doboru próby zastosowano losowanie warstwowe, przy czym przynależność do warstwy zależała od 3 cech: regionu kraju, typu produkcyjnego i wielkości ekonomicznej.

Rysunek 1. Podział Polski na regiony zgodnie z metodologią FADN



Źródło: opis realizacji planu wyboru próby gospodarstw rolnych dla Polskiego FADN w 2012 roku (Goraj, Malanowska, Osuch, Sierański, 2012).

Typu produkcyjny – 4 poziomy:

1. produkcja roślinna,
2. bydło,
3. trzoda,
4. mieszane.

Wielkości ekonomiczna – 3 poziomy:

1. od 4 tys. do 25 tys. euro,
2. od 25 tys. do 100 tys. euro,
3. powyżej 100 tys. euro.

Dla tak określonych warstw ustalono liczebności zgodnie z metodą optymalnej alokacji Neymana, uzyskując ostatecznie próbę o rozmiarze 590 gospodarstw.

Poza zmienną objaśnianą Y określającą ubezpieczenie upraw przez rolnika (1 – ubezpieczenie upraw, 0 – brak ubezpieczenia) rozpatrywano następujące zmienne z podziałem na zmienne dotyczące rolnika i zmienne dotyczące gospodarstwa:

– zmienne charakteryzujące rolnika:

- X_1 – płeć,
- X_2 – wiek,

- X_3 – wykształcenie (zmienna jakościowa, 4 poziomy),
 X_4 – deklarowany stosunek do ryzyka (1 – lubi ryzyko, 0 – unika ryzyka);
– zmienne charakteryzujące gospodarstwo:
 X_5 – region kraju,
 X_6 – typ produkcyjny,
 X_7 – wielkość ekonomiczna,
 X_8 – wystąpienie znaczących szkód w przeszłości (1 – szkody występowały,
0 – szkody nie występowały)

oraz dodatkowe dwie zmienne związane z metodą doboru próby: warstwa określająca przynależność gospodarstwa do jednej z 48 wyróżnionych warstw i waga będąca ilorzem liczebności warstwy w populacji do liczebności warstwy w próbie.

2. Metody

Z uwagi na binarny charakter zmiennej $Y_i \sim D(\pi_i)$ zastosowano uogólniony model liniowy, przyjmując jako funkcję łączącą *logit*:

$$\text{logit}(\pi_i) = \log\left(\frac{\pi_i}{1 - \pi_i}\right) \quad (1)$$

W konsekwencji poniższe równanie opisuje zależność funkcji wartości oczekiwanej zmiennej Y_i i zmiennych objaśniających:

$$\text{logit}(\pi_i) = \beta_0 + \mathbf{x}_i \boldsymbol{\beta} \quad (2)$$

gdzie: β_0 oznacza wyraz wolny, \mathbf{x}_i wektor obserwacji zmiennych niezależnych dla i -tego gospodarstwa, a $\boldsymbol{\beta}$ jest wektorem współczynników regresji.

Z uwagi na losowanie warstwowe w doborze próby do estymacji parametrów modelu (2) zastosowano estymator Horwitza-Thompsona wiarygodności dla populacji. Do obliczeń wykorzystano środowisko R (R Core Team, 2015) oraz pakiet survey. Poniżej zaprezentowany jest fragment skryptu z definicją modelu:

```
plan<-svydesign(id=~1, strata=~Warstwa, weights=~Waga, data=dane)
model<-svyglm(U~X1+X2+X3+X4+X5+X6+X7+X8, design=plan,
              family=quasibinomial())
```

W przypadku zmiennych ilościowych i binarnych sprawdzenie istotności wpływu danej zmiennej może polegać na wynikach oszacowania parametrów modelu i istotności tych parametrów, jednak w przypadku zmiennych czynnikowych (liczba poziomów > 2) wyniki istotności parametru dotyczą tylko istotności różnicy

efektów badanego poziomu czynnika i poziomu referencyjnego. Dlatego konieczne jest zastosowanie testu weryfikującego hipotezę dotyczącą wielu parametrów jednocześnie. Jednym z takich testów jest zastosowany w pracy test Walda przy użyciu funkcji `regTermTest()` z pakietu `survey` (Lumley, 2014).

Z uwagi na nieliniowy charakter modelu regresji logistycznej ocena wartości parametru nie pozwala w bezpośredni sposób ocenić wpływu zmiennej na warunkową wartość oczekiwaną. W zależności od wartości pozostałych zmiennych efekt będzie przyjmował różne wartości. Rozwiązaniem jest obliczenie efektów marginalnych. W literaturze (np. Greene, 1997) spotykane są dwa podejścia: efekt marginalny obliczany dla średnich wartości zmiennych objaśniających i w przypadku regresji logitowej przyjmuje następującą postać:

$$MEM_k = \text{inv. logit}(\beta_0 + \bar{\mathbf{x}}\boldsymbol{\beta} + \beta_k) - \text{inv. logit}(\beta_0 + \bar{\mathbf{x}}\boldsymbol{\beta}) \quad (3)$$

gdzie `inv.logit(.)` oznacza funkcję odwrotną do funkcji `logit`, oraz średni efekt marginalny uzyskiwany przez uśrednienie efektów marginalnych obliczonych dla wszystkich jednostek w próbie:

$$EME_k = \frac{1}{n} \sum_{i=1}^n (\text{inv. logit}(\beta_0 + \mathbf{x}_i\boldsymbol{\beta} + \beta_k) - \text{inv. logit}(\beta_0 + \mathbf{x}_i\boldsymbol{\beta})) \quad (4)$$

Chociaż wyznaczenie *EME* jest bardziej kłopotliwe z powodu konieczności obliczenia wartości efektu marginalnego dla każdej jednostki próby, to jest ono znacznie lepszym przybliżeniem przeciętnego efektu marginalnego w populacji.

Z uwagi na losowanie warstwowe podczas obliczania średniej wartości efektu marginalnego należy uwzględnić wagi poszczególnych obserwacji:

$$wEME_k = \sum_{i=1}^n (\text{inv. logit}(\beta_0 + \mathbf{x}_i\boldsymbol{\beta} + \beta_k) - \text{inv. logit}(\beta_0 + \mathbf{x}_i\boldsymbol{\beta})) \frac{w_i}{\sum w_i} \quad (5)$$

3. Wyniki

W tabeli 1 podane zostały wyniki oszacowania pełnego modelu z 8 zmiennymi objaśniającymi. Wartości ocen parametrów wymagają pewnego wyjaśnienia. Wartość wyrazu wolnego można interpretować jako przeciętną wartość funkcji `logit` w przypadku zerowych wartości ilościowych zmiennych objaśniających i pozostawiania zmiennych czynnikowych na poziomie referencyjnym. W opracowaniu przyjęto następujące poziomy referencyjne: dla X_1 (płeć) – poziom k , dla X_3 (wykształcenie) – poziom p (podstawowe), dla X_5 (region kraju) – poziom 785 (region północno-zachodni), dla X_6 (typ produkcyjny) – poziom 1 (produkcja roślinna), dla

X_7 (wielkość ekonomiczna) – poziom 1 (4 tys. do 25 tys. euro) i dla X_8 (występowanie szkód w przeszłości) – poziom n .

Tabela 1. Wyniki oszacowania pełnego modelu

	Ocena	Błąd stand.	t	$P(> t)$
w. wolny	-1.5390	1.0824	-1.4218	0.1557
$X_{1,m}$	0.4761	0.3505	1.3583	0.1750
X_2	-0.0053	0.0156	-0.3432	0.7316
X_3,z	0.1148	0.4938	0.2325	0.8162
$X_3,\$$	0.4595	0.5078	0.9049	0.3660
X_3,w	0.7542	0.6264	1.2042	0.2291
X_4	-0.0292	0.0482	-0.6052	0.5453
$X_5,790$	0.9606	0.3751	2.5609	0.0107
$X_5,795$	-1.0401	0.3814	-2.7270	0.0066
$X_5,800$	-1.1810	0.4851	-2.4347	0.0152
$X_6,2$	-0.9033	0.3275	-2.7581	0.0060
$X_6,3$	-0.6258	0.5024	-1.2457	0.2134
$X_6,4$	-0.2316	0.2985	-0.7759	0.4382
$X_7,2$	0.5242	0.2514	2.0846	0.0376
$X_7,3$	0.9614	0.3749	2.5643	0.0106
X_8,t	0.8793	0.3740	2.3512	0.0191

Źródło: obliczenia własne.

W przypadku zmiennych ilościowych X_2 i X_4 oraz zmiennej binarnej X_1 wartości statystyki t , a dokładniej prawdopodobieństwa $P(> |t|)$, pozwalają stwierdzić brak istotnego wpływu na prawdopodobieństwo podjęcia decyzji o ubezpieczeniu upraw, a w przypadku zmiennej binarnej X_8 potwierdzają jej wpływ na wspomnianą decyzję.

W przypadku pozostałych zmiennych z uwagi na ich charakter konieczne jest zastosowanie testu Walda, którego wyniki podano w tabeli 2.

Tabela 2. Wyniki testu Walda

Zmienna	<i>F</i>	<i>St. sw. 1</i>	<i>St. sw. 2</i>	<i>p</i>
X_1	1.8450	1	516	0.1750
X_2	0.1178	1	516	0.7316
X_3	1.0677	3	516	0.3624
X_4	0.3662	1	516	0.5453
X_5	18.2144	3	516	0.0000
X_6	2.7464	3	516	0.0424
X_7	4.0147	2	516	0.0186
X_8	5.5280	1	516	0.0191

Źródło: obliczenia własne.

Na podstawie wyników testu Walda można stwierdzić na poziomie istotności 0,05, że przeprowadzone badania nie dają dowodów wpływu pierwszych 4 zmiennych na decyzje rolników o ubezpieczeniu upraw. Ponieważ jednak zmienne objaśniające nie są od siebie niezależne, usunięcie wszystkich 4 zmiennych jednocześnie byłoby niewłaściwe. Do selekcji ostatecznego modelu zastosowano regresję krokową w tył. Jednak niezależnie od zastosowania regresji krokowej ostatecznie w modelu pozostały tylko te 4 zmienne, które były istotne w pełnym modelu, chociaż zgodnie z tabelą 3 nastąpiły pewne niewielkie zmiany wartości *p*.

Tabela 3. Wyniki testu Walda dla modelu końcowego

Zmienna	<i>F</i>	<i>St. sw. 1</i>	<i>St. sw. 2</i>	<i>p</i>
X_5	18.1588	3	522	0.0000
X_6	3.5512	3	522	0.0144
X_7	5.2908	2	522	0.0053
X_8	5.0500	1	522	0.0250

Źródło: obliczenia własne.

Warto w tym momencie przypomnieć, że pierwsze 4 zmienne: X_1 , X_2 , X_3 i X_4 dotyczyły rolnika i były to odpowiednio: płeć, wiek, wykształcenie i deklarowany stosunek do ryzyka. Natomiast zmienne: X_5 , X_6 , X_7 i X_8 charakteryzowały gospodarstwo i były to odpowiednio: region kraju, typ produkcyjny, wielkość ekonomiczna i wystąpienie znaczących szkód w przeszłości. Uzyskane wyniki wskazują, że żadna z rozpatrywanych cech rolnika nie wykazuje wpływu na podjęcie decyzji o ubez-

pieczeniu upraw, natomiast wszystkie badane charakterystyki gospodarstwa taki wpływ wykazują. Takie rezultaty w pewnym stopniu potwierdzają racjonalność zachowań rolników, ponieważ decyzja o ubezpieczeniu bądź nieubezpieczeniu upraw powinna wynikać z charakterystyki gospodarstwa.

Tabela 4. Wyniki oszacowania końcowego modelu

	Średni efekt marginalny	Ocena	Błąd stand.	<i>t</i>	<i>P</i> (> <i>t</i>)
w. wolny	–	–1.1636	0.4877	–2.3857	0.0174
X ₅ 790	0.1808	0.9826	0.3919	2.5074	0.0125
X ₅ 795	–0.1551	–0.9470	0.3966	–2.3877	0.0173
X ₅ 800	–0.1550	–1.0879	0.4975	–2.1869	0.0292
X ₆ 2	–0.1506	–1.0200	0.3247	–3.1409	0.0018
X ₆ 3	–0.0903	–0.6498	0.4972	–1.3070	0.1918
X ₆ 4	–0.0440	–0.2876	0.3012	–0.9550	0.3400
X ₇ 2	0.1057	0.6312	0.2430	2.5971	0.0097
X ₇ 3	0.1767	0.9936	0.3489	2.8477	0.0046
X ₈ t	0.1164	0.8145	0.3625	2.2472	0.0250

Źródło: obliczenia własne.

Analizując szczegółowo wpływ poszczególnych zmiennych, można zauważyć, że lokalizacja gospodarstwa w regionie 790 obejmującym województwa: wielkopolskie, dolnośląskie, kujawsko-pomorskie i opolskie zwiększa szansę ubezpieczenia upraw średnio o 0.18, podczas gdy lokalizacja w regionach 795 i 800 zmniejsza szansę ubezpieczenia średnio o około 0.15. Równie silny wpływ dotyczy także wielkości ekonomicznej. W przypadku gospodarstw o standardowej produkcji powyżej 100 tys. euro średni wzrost prawdopodobieństwa wynosi prawie 0.18. Fakt doświadczenia w przeszłości szkód w uprawach zwiększał przeciętnie szansę ubezpieczenia o około 0.11.

4. Dyskusja

Porównując uzyskane wyniki z wnioskami z prac (Stempel, 2013) i (Wicka, 2013), należy stwierdzić tylko częściową zgodność. Przypomnijmy, w pracy (Stempel, 2013) stwierdzono pozytywny wpływ powierzchni upraw, wykształcenia rolników oraz stażu w prowadzeniu gospodarstwa. W przypadku wykształcenia wartości ocen

parametrów dla kolejnych poziomów wykształcenia z tabeli 1 przyjmują coraz wyższe wartości dodatnie, co mogłoby świadczyć o pozytywnym wpływie wykształcenia, podobnie jak stwierdzono to w pracy (Stempel, 2013), jednak wyniki testu Walda podane w tabeli 2 nie potwierdzają istotności tego efektu. Staż w prowadzeniu gospodarstwa nie jest funkcją liniową wieku kierownika gospodarstwa, ale niewątpliwie są to zmienne silnie skorelowane. Jednak wyniki z tabeli 2 wskazują, że wiek nie miał żadnego wpływu na podjęcie decyzji o wykupieniu ubezpieczenia. Powierzchnia upraw jest zmienną związaną z typem produkcji roślinnej i wielkością ekonomiczną. Wyniki z tabeli 4 potwierdzają, że przynależność do typu produkcji roślinnej i wielkość gospodarstwa wykazują silny pozytywny wpływ na ubezpieczenie upraw.

W pracy (Wicka, 2013) potwierdzono pozytywny wpływ wielkości powierzchni użytków rolnych, udziału produkcji roślinnej w sprzedaży ogółem oraz dochodu brutto na ubezpieczenie upraw. Przyjmując, że udział produkcji w sprzedaży ogółem jest związany z typem produkcji, a wielkość użytków rolnych i dochód brutto z wielkością ekonomiczną, należy stwierdzić, że pomimo wspomnianych we wstępie braków metodycznych w pracy (Wicka, 2013) prezentowane tam wyniki są zbieżne do kierunku i istotności badanych zależności z wynikami uzyskanymi w niniejszym opracowaniu.

Podsumowanie

1. Cechy standardowo utożsamiane ze stosunkiem do ryzyka, takie jak: płeć, wiek, wykształcenie czy nawet samocena stosunku do ryzyka, nie miały wpływu na decyzję dotyczącą ubezpieczenia upraw.
2. Najsilniejszymi czynnikami determinującymi ubezpieczenie upraw były: wielkość ekonomiczna (wpływ pozytywny), doświadczenie w przeszłości szkód w uprawach oraz region kraju. Przynależność do regionu 790 silnie zwiększała szanse ubezpieczenia, natomiast przynależność do regionów 795 i 800 znacząco zmniejszała szanse ubezpieczenia upraw.
3. Również przynależność do roślinnego typu produkcji zwiększa w pewnym stopniu szanse ubezpieczenia upraw.
4. Uzyskane wyniki wskazują, że decyzja o ubezpieczeniu upraw zależy przede wszystkim od charakterystyki gospodarstwa: rodzaju produkcji, wielkości ekonomicznej i częstości występowania szkód.

Literatura

- Goraj, L., Małanowska, B., Osuch, D., Sierański, W. (2012). *Opis realizacji planu wyboru próby gospodarstw rolnych dla Polskiego FADN w 2012 roku*. Warszawa: Polski FADN.
- Greene, W.H. (1997). *Econometric Analysis*. Upper Saddle River, NJ: Prentice Hall.
- GUS (2014). *Charakterystyka gospodarstw rolnych w 2013 r.* Warszawa.
- Lumley, T. (2014). *Survey: Analysis of Complex Survey Samples*. R package version 3.30.
- NIK (2014). *Informacja o wynikach kontroli wykonania budżetu państwa w 2013 r. w częściach 32 Rolnictwo, 33 Rozwój wsi, 35 Rynki rolne, 62 Rybołówstwo*. Pobrane z: <https://www.nik.gov.pl/plik/id,6847.pdf> (6.10.2015).
- R Core Team (2015). *R: A Language and Environment for Statistical Computing*. Vienna: R Foundation for Statistical Computing. Pobrane: <http://www.R-project.org/> (9.03.2015).
- Stempel, R. (2013). Ubezpieczenie upraw polowych na terenie Polski północnej. *Ubezpieczenia w Rolnictwie. Materiały i Studia*, 47, 7–22.
- Wicka, O. (red.). (2013). *Czynniki i możliwości ograniczania ryzyka w produkcji roślinnej poprzez ubezpieczenia*. Warszawa: Wyd. SGGW.

DETERMINANTS OF AGRICULTURAL INSURANCE

Abstract

Despite a specific law obligation to insure at least 50% of the areas, only about 11% of the farmers insure crops. In order to identify the determinants of the crop insurance level in agriculture paper analysed the impact of variables characterizing the farmer: gender, age, education, declared attitude towards the risks and variables characterizing the farm: region of the country, type of production, economic size, of significant damage in the past. Based on a sample of 590 farms, using logistic regression, it was found that: the economic size, membership to the type of crop production, the location of the region 790 (Wielkopolska, Lower Silesia, Kujawy-Pomerania and Opole) and the existence of previous damage to crops had a positive impact on the probability of crops insurance.

Translated by Paweł Kobus

Keywords: crop insurance, stratified sampling, logit regression

JEL Codes: C25, C83, G22, Q14

