

Modele warunkowej heteroscedastyczności

- Niskie koszty transakcyjne

- Niskie koszty transakcyjne
- Racjonalne oczekiwania inwestorów

$$P_t = \frac{E(P_{t+1} | I_t)}{1 + R} \quad (1)$$

- Niskie koszty transakcyjne
- Racjonalne oczekiwania inwestorów

$$P_t = \frac{E(P_{t+1} | I_t)}{1 + R} \quad (1)$$

- Jeżeli równość (1) jest spełniona to nie ma możliwości arbitrażu

- Niskie koszty transakcyjne
- Racjonalne oczekiwania inwestorów

$$P_t = \frac{E(P_{t+1} | I_t)}{1 + R} \quad (1)$$

- Jeżeli równość (1) jest spełniona to nie ma możliwości arbitrażu
- Równanie (1) nazywane jest hipotezą rynku efektywnego

- Jeżeli I_t zawiera jedynie ceny z przeszłości, to

$$E(P_t | P_{t-1}, P_{t-2}, \dots) = P_{t-1}(1 + R)$$

- Jeżeli I_t zawiera jedynie ceny z przeszłości, to

$$E(P_t | P_{t-1}, P_{t-2}, \dots) = P_{t-1}(1 + R)$$

- Dzieląc obie strony przez P_{t-1} i logarytmując

$$E(\Delta \ln P_t | P_{t-1}, P_{t-2}, \dots) = \ln(1 + R)$$

- Jeżeli I_t zawiera jedynie ceny z przeszłości, to

$$E(P_t | P_{t-1}, P_{t-2}, \dots) = P_{t-1}(1 + R)$$

- Dzieląc obie strony przez P_{t-1} i logarytmując

$$E(\Delta \ln P_t | P_{t-1}, P_{t-2}, \dots) = \ln(1 + R)$$

- Oznaczając $p_t = \ln(P_t)$ oraz $r = \ln(1 + R)$ oraz definiując $\varepsilon_t = \Delta p_t - r$ uzyskujemy


$$\Delta p_t = r + \varepsilon_t$$


gdzie $E(\varepsilon_t | P_t, P_{t-1}, \dots) = 0 \Leftrightarrow E(\varepsilon_t | \varepsilon_t, \varepsilon_{t-1}, \dots) = 0$

- Przyrost ceny ma warunkową wartość oczekiwaną r

- Przyrost ceny ma warunkową wartość oczekiwaną r
- Nie jest możliwe przewidzenie przyszłych cen

- Przyrost ceny ma warunkową wartość oczekiwaną r
- Nie jest możliwe przewidzenie przyszłych cen
- Logarytmy cen zachowują się zgodnie z procesem błędzenia przypadkowego





Stacjonarność logarytmu WIG

```
. dfuller lnwig, lags(20) reg
```

```
Augmented Dickey-Fuller test for unit root           Number of obs   =           3598
```

Test Statistic	----- Interpolated Dickey-Fuller -----			
	1% Critical Value	5% Critical Value	10% Critical Value	
Z(t)	-1.676	-3.430	-2.860	-2.570

```
MacKinnon approximate p-value for Z(t) = 0.4433
```

Stacjonarność logarytmu WIG


```
. dfuller lnwig, lags(20) reg
```

```
Augmented Dickey-Fuller test for unit root           Number of obs   =           3598
```

Test Statistic	----- Interpolated Dickey-Fuller -----			
	1% Critical Value	5% Critical Value	10% Critical Value	
Z(t)	-1.676	-3.430	-2.860	-2.570

```
MacKinnon approximate p-value for Z(t) = 0.4433
```

- Zatem logarytm WIG jest niestacjonarny



Stacjonarność zwrotów z WIG

```
. dfuller dlnwig, lags(20) reg
```

```
Augmented Dickey-Fuller test for unit root           Number of obs   =           3597
```

```
----- Interpolated Dickey-Fuller -----
                Test                1% Critical    5% Critical    10% Critical
                Statistic           Value           Value           Value
-----
Z(t)            -12.776             -3.430         -2.860         -2.570
-----
```

```
MacKinnon approximate p-value for Z(t) = 0.0000
```

Stacjonarność zwrotów z WIG

```
. dfuller dlnwig, lags(20) reg
```

```
Augmented Dickey-Fuller test for unit root           Number of obs   =           3597
```

```
----- Interpolated Dickey-Fuller -----  
                Test                1% Critical    5% Critical    10% Critical  
                Statistic            Value           Value           Value  
-----  
Z(t)             -12.776             -3.430         -2.860         -2.570  
-----
```

```
MacKinnon approximate p-value for Z(t) = 0.0000
```

- Zatem logarytmiczna stopa zwrotu z WIG jest stacjonarna

Czy zwrot z WIG jest białym szumem

- test Ljung-Boxa dla WIG

Portmanteau test for white noise

Portmanteau (Q) statistic =	133.7683
Prob > chi2(40) =	0.0000


Czy zwrot z WIG jest białym szumem


- test Ljung-Boxa dla WIG



Portmanteau test for white noise

Portmanteau (Q) statistic =	133.7683
Prob > chi2(40) =	0.0000

- Na podstawie wartości statystyki testowej wnioskujemy, że WIG nie zachowuje się jak biały szum







	stopa zwrotu	logarytm stopy zwrotu
Obs	3618	3618
Mean	3.904251	.0002526
Std. Dev.	389.6439	.0163453
Variance	151822.4	.0002672
Skewness	-.6254877	-.2051489
Kurtosis	10.68253	6.120451

- Zatem rozkład zwroty charakteryzuje się grubymi ogonami

- W sposób ogólny warunkową heteroscedastyczność definiuje się następująco


$$\sigma_t^2 = E(\varepsilon_t^2 \mid \varepsilon_{t-1}, \varepsilon_{t-2}, \dots, \varepsilon_{t-k}) \neq E(\varepsilon_t^2)$$

- W sposób ogólny warunkową heteroscedastyczność definiuje się następująco

$$\sigma_t^2 = E(\varepsilon_t^2 | \varepsilon_{t-1}, \varepsilon_{t-2}, \dots, \varepsilon_{t-k}) \neq E(\varepsilon_t^2)$$

- Najprostszym wariantem jest proces **AutoRegressive Conditional Heteroscedasticity**

$$\sigma_t^2 = E(\varepsilon_t^2 | \varepsilon_{t-1}, \varepsilon_{t-2}, \dots, \varepsilon_{t-k}) = \alpha_0 + \alpha_1 \varepsilon_{t-1}^2 + \dots + \alpha_k \varepsilon_{t-k}^2$$



- Występowanie zjawiska warunkowej heteroscedastyczności reszt bada się testem ARCHLM

$$H_0 : E(\varepsilon_t^2 \mid \varepsilon_{t-1}, \varepsilon_{t-2}, \dots, \varepsilon_{t-k}) = E(\varepsilon^2)$$

$$H_1 : E(\varepsilon_t^2 \mid \varepsilon_{t-1}, \varepsilon_{t-2}, \dots, \varepsilon_{t-k}) \neq E(\varepsilon^2)$$

- Występowanie zjawiska warunkowej heteroscedastyczności reszt bada się testem ARCHLM

$$H_0 : E(\varepsilon_t^2 \mid \varepsilon_{t-1}, \varepsilon_{t-2}, \dots, \varepsilon_{t-k}) = E(\varepsilon^2)$$

$$H_1 : E(\varepsilon_t^2 \mid \varepsilon_{t-1}, \varepsilon_{t-2}, \dots, \varepsilon_{t-k}) \neq E(\varepsilon^2)$$

- statystyka testowa ma rozkład $\chi^2(k)$

- Procedura testowa przebiega następująco

- Procedura testowa przebiega następująco
 - ① Szacujemy parametry modelu i reszty

- Procedura testowa przebiega następująco
 - 1 Szacujemy parametry modelu i reszty
 - 2 Reszty e podnosimy do kwadratu

- Procedura testowa przebiega następująco

- 1 Szacujemy parametry modelu i reszty
- 2 Reszty e podnosimy do kwadratu
- 3 Szacujemy model autoregresyjny dla kwadratów reszt zapamiętując R_0^2

$$e_t^2 = \alpha_0 + \alpha_1 e_{t-1}^2 + \dots + \alpha_q e_{t-q}^2$$

- Procedura testowa przebiega następująco

- 1 Szacujemy parametry modelu i reszty
- 2 Reszty e podnosimy do kwadratu
- 3 Szacujemy model autoregresyjny dla kwadratów reszt zapamiętując R_0^2

$$e_t^2 = \alpha_0 + \alpha_1 e_{t-1}^2 + \dots + \alpha_q e_{t-q}^2$$

- 4 Testujemy łączną nieistotność parametrów $\alpha_1, \dots, \alpha_q$

- Procedura testowa przebiega następująco

- 1 Szacujemy parametry modelu i reszty
- 2 Reszty e podnosimy do kwadratu
- 3 Szacujemy model autoregresyjny dla kwadratów reszt zapamiętując R_0^2

$$e_t^2 = \alpha_0 + \alpha_1 e_{t-1}^2 + \dots + \alpha_q e_{t-q}^2$$

- 4 Testujemy łączną nieistotność parametrów $\alpha_1, \dots, \alpha_q$
- 5 W tym celu budujemy statystykę

$$ARCHLM = TR_0^2 \stackrel{a}{\sim} \chi^2(q)$$

. reg lnwig L.lnwig

Source	SS	df	MS	Number of obs =	3618
Model	1096.49595	1	1096.49595	F(1, 3616) =	.
Residual	.965847543	3616	.000267104	Prob > F =	0.0000
Total	1097.4618	3617	.303417694	R-squared =	0.9991
				Adj R-squared =	0.9991
				Root MSE =	.01634

lnwig	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]
lnwig					
L1.	.9993261	.0004932	2026.11	0.000	.9983591 1.000293
_cons	.0069187	.0048866	1.42	0.157	-.002662 .0164995

. estat archlm

LM test for autoregressive conditional heteroskedasticity (ARCH)

lags(p)	chi2	df	Prob > chi2
1	276.747	1	0.0000

H0: no ARCH effects vs. H1: ARCH(p) disturbance

ARCH

- Podstawowym modelem jest model ARCH(q).

$$y_t = X_t\beta + \varepsilon_t \quad E(\varepsilon_t | X_t) = 0$$
$$\varepsilon_t = u_t \sqrt{\theta_0 + \theta_1 \varepsilon_{t-1}^2 + \dots + \theta_q \varepsilon_{t-q}^2} \quad u_t \sim_{IID} \mathcal{N}(0, 1)$$

ARCH

- Podstawowym modelem jest model ARCH(q).

$$y_t = X_t\beta + \varepsilon_t \quad E(\varepsilon_t | X_t) = 0$$
$$\varepsilon_t = u_t \sqrt{\theta_0 + \theta_1 \varepsilon_{t-1}^2 + \dots + \theta_q \varepsilon_{t-q}^2} \quad u_t \sim_{IID} \mathcal{N}(0, 1)$$

- Pierwsze równanie opisuje średnią, drugie wariancję.

ARCH

- Równoważnym sposobem zapisu modelu jest

$$y_t = X_t\beta + \varepsilon_t \quad E(\varepsilon_t | X_t) = 0$$

$$\varepsilon_t = u_t\sigma_t$$

$$\sigma_t^2 = \theta_0 + \theta_1\varepsilon_{t-1}^2 + \dots + \theta_q\varepsilon_{t-q}^2$$

ARCH

- W modelu ARCH(q) warunkowa wariancja nie jest stała, ponieważ

$$\sigma_t^2 = \text{var}(\varepsilon_t \mid \varepsilon_{t-1}, \dots, \varepsilon_{t-q}) = (\theta_0 + \theta_1 \varepsilon_{t-1}^2 + \dots + \theta_q \varepsilon_{t-q}^2) \text{var}(u_t)$$

ARCH

- W modelu ARCH(q) warunkowa wariancja nie jest stała, ponieważ

$$\sigma_t^2 = \text{var}(\varepsilon_t \mid \varepsilon_{t-1}, \dots, \varepsilon_{t-q}) = (\theta_0 + \theta_1 \varepsilon_{t-1}^2 + \dots + \theta_q \varepsilon_{t-q}^2) \text{var}(u_t)$$

$$\sigma_t^2 = \theta_0 + \theta_1 \varepsilon_{t-1}^2 + \dots + \theta_q \varepsilon_{t-q}^2$$

ARCH

- W modelu ARCH(q) warunkowa wariancja nie jest stała, ponieważ

$$\sigma_t^2 = \text{var}(\varepsilon_t \mid \varepsilon_{t-1}, \dots, \varepsilon_{t-q}) = (\theta_0 + \theta_1 \varepsilon_{t-1}^2 + \dots + \theta_q \varepsilon_{t-q}^2) \text{var}(u_t)$$

$$\sigma_t^2 = \theta_0 + \theta_1 \varepsilon_{t-1}^2 + \dots + \theta_q \varepsilon_{t-q}^2$$

- Pomimo tego wariancja bezwarunkowa jest stała, jeśli ε_t jest stacjonarnym procesem stochastycznym, ponieważ

$$\text{var}(\varepsilon_t) = \text{var}(\varepsilon_{t-1}) = \dots = \text{var}(\varepsilon_{t-q})$$

ARCH

- Przekształcając równanie warunkowej wariancji uzyskujemy

$$\text{var}(\varepsilon_t) = E(\varepsilon_t^2) = E(\theta_0 + \theta_1\varepsilon_{t-1}^2 + \dots + \theta_q\varepsilon_{t-q}^2)E(u_t^2) =$$

ARCH

- Przekształcając równanie warunkowej wariancji uzyskujemy

$$\text{var}(\varepsilon_t) = E(\varepsilon_t^2) = E(\theta_0 + \theta_1\varepsilon_{t-1}^2 + \dots + \theta_q\varepsilon_{t-q}^2)E(u_t^2) =$$

$$\text{var}(\varepsilon_t) = \theta_0 + \theta_1\text{var}(\varepsilon_{t-1}^2) + \dots + \theta_q\text{var}(\varepsilon_{t-q}^2)$$

ARCH

- Przekształcając równanie warunkowej wariancji uzyskujemy

$$\text{var}(\varepsilon_t) = E(\varepsilon_t^2) = E(\theta_0 + \theta_1\varepsilon_{t-1}^2 + \dots + \theta_q\varepsilon_{t-q}^2)E(u_t^2) =$$

$$\text{var}(\varepsilon_t) = \theta_0 + \theta_1\text{var}(\varepsilon_{t-1}^2) + \dots + \theta_q\text{var}(\varepsilon_{t-q}^2)$$

- wobec tego

$$\text{var}(\varepsilon_t) = \frac{\theta_0}{1 - \theta_1 - \dots - \theta_q} = \sigma^2$$

ARCH

- Przekształcając równanie warunkowej wariancji uzyskujemy

$$\text{var}(\varepsilon_t) = E(\varepsilon_t^2) = E(\theta_0 + \theta_1\varepsilon_{t-1}^2 + \dots + \theta_q\varepsilon_{t-q}^2)E(u_t^2) =$$

$$\text{var}(\varepsilon_t) = \theta_0 + \theta_1\text{var}(\varepsilon_{t-1}^2) + \dots + \theta_q\text{var}(\varepsilon_{t-q}^2)$$

- wobec tego

$$\text{var}(\varepsilon_t) = \frac{\theta_0}{1 - \theta_1 - \dots - \theta_q} = \sigma^2$$

- gdzie σ^2 jest bezwarunkową wariancją

Szacowanie modelu ARCH

- MNK do równania średniej

Szacowanie modelu ARCH

- MNK do równania średniej
- MNK dla modelu autoregresyjnego dla reszt

Szacowanie modelu ARCH

- MNK do równania średniej
- MNK dla modelu autoregresyjnego dla reszt
- Dzięki temu uzyskuje się zgodne estymatory

Szacowanie modelu ARCH

- MNK do równania średniej
- MNK dla modelu autoregresyjnego dla reszt
- Dzięki temu uzyskuje się zgodne estymatory
- Estymatory efektywne otrzymuje się wykorzystując MNW

- Najważniejsza różnica między modelem regresji a ARCH polega na innym sposobie szacowania błędu prognozy

- Najważniejsza różnica między modelem regresji a ARCH polega na innym sposobie szacowania błędu prognozy
- Nieobciążoną prognozą dla y_{t+1} jest $X_{t+1}\hat{\beta}$

- Najważniejsza różnica między modelem regresji a ARCH polega na innym sposobie szacowania błędu prognozy
- Nieobciążoną prognozą dla y_{t+1} jest $X_{t+1}\hat{\beta}$
- Jej wariancja jest równa

$$\text{var}(x_{T+1}b) = \sigma^2 x'_{T+1} (X'X)^{-1} x_{T+1} + \sigma^2$$

- Najważniejsza różnica między modelem regresji a ARCH polega na innym sposobie szacowania błędu prognozy
- Nieobciążoną prognozą dla y_{t+1} jest $X_{t+1}\hat{\beta}$
- Jej wariancja jest równa

$$\text{var}(x_{T+1}b) = \sigma^2 x'_{T+1} (X'X)^{-1} x_{T+1} + \sigma^2$$

- dla składnika losowego zawierającego proces warunkowej heteroscedastyczności

$$\text{var}(x_{T+1}b \mid \varepsilon_{t-1}, \dots, \varepsilon_{t-q}) = x'_{T+1} \sigma^2_{T+1} (X'X)^{-1} x_{T+1} + \sigma^2$$

gdzie

$$\sigma^2_{T+1} = \hat{\theta}_0 + \hat{\theta}_1 e^2_T + \dots + \hat{\theta}_q e^2_{T-q+1}$$

ARCH family regression -- AR disturbances

Sample: 2 - 3619

Distribution: Gaussian

Log likelihood = 9946.637

Number of obs = 3618

Wald chi2(1) = 71.18

Prob > chi2 = 0.0000

		Coef.	OPG Std. Err.	z	P> z	[95% Conf. Interval]	
-----+-----							
dlnwig							
_cons		.000255	.0002659	0.96	0.338	-.0002661	.0007761
-----+-----							
ARMA							
ar							
L1.		.1209841	.01434	8.44	0.000	.0928782	.14909
-----+-----							
ARCH							
arch							
L1.		.3121721	.021704	14.38	0.000	.269633	.3547112
_cons		.000183	4.20e-06	43.61	0.000	.0001748	.0001912
-----+-----							

GARCH

- Rozszerzenia podstawowego modelu

GARCH

- Rozszerzenia podstawowego modelu
- Specyfikacja ARCH wymaga nieujemności parametrów

GARCH

- Rozszerzenia podstawowego modelu
- Specyfikacja ARCH wymaga nieujemności parametrów
- Bardziej ogólną formą jest model GARCH(p,q)

$$y_t = X_t\beta + \varepsilon_t$$

$$\varepsilon_t = u_t\sigma_t$$

$$\sigma_t^2 = \alpha_1\sigma_t^2 - 1 + \dots + \alpha_p\sigma_{t-p}^2 + \theta_0 + \theta_1\varepsilon_{t-1}^2 + \dots + \theta_q\varepsilon_{t-q}^2$$

GARCH

- Równanie wariancji składa się z części autoregresyjnej i części opisującej warunkową wariancję

GARCH

- Równanie wariancji składa się z części autoregresyjnej i części opisującej warunkową wariancję
- Model jest szacowany MNW

GARCH

- Równanie wariancji składa się z części autoregresyjnej i części opisującej warunkową wariancję
- Model jest szacowany MNW
- W praktyce ma on mniejszą liczbę parametrów niż model ARCH

ARCH family regression -- AR disturbances

Sample: 2 - 3619

Distribution: Gaussian

Log likelihood = 10212.72

Number of obs = 3618

Wald chi2(1) = 59.26

Prob > chi2 = 0.0000

	Coef.	OPG Std. Err.	z	P> z	[95% Conf. Interval]	

dlnwig						
_cons	.0007063	.000257	2.75	0.006	.0002026	.00121

ARMA						
ar						
L1.	.1341403	.0174245	7.70	0.000	.0999889	.1682917

ARCH						
arch						
L1.	.0946308	.0060918	15.53	0.000	.082691	.1065705
garch						
L1.	.8885389	.007568	117.41	0.000	.873706	.9033719
_cons	4.62e-06	7.64e-07	6.05	0.000	3.13e-06	6.12e-06

TARCH

- Asymetryczność zmian cen

TARCH

- Asymetryczność zmian cen
- Modelem uwzględniającym ten efekt jest TARCH

$$y_t = X_t\beta + \varepsilon_t$$

$$\varepsilon_t = u_t\sigma_t$$

$$\sigma_t^2 = \begin{cases} \theta_0 + \theta_1\varepsilon_{t-1} + \dots + \theta_q\varepsilon_{t-q} \\ \theta_0 + \theta_1\varepsilon_{t-1}^* + \dots + \theta_q\varepsilon_{t-q}^* \end{cases}$$

ARCH family regression -- AR disturbances

Sample: 2 - 3619

Distribution: Gaussian

Log likelihood = 10034.44

Number of obs = 3618

Wald chi2(1) = 206.11

Prob > chi2 = 0.0000

		Coef.	OPG Std. Err.	z	P> z	[95% Conf. Interval]	
dlnwig							
	_cons	.000522	.000286	1.82	0.068	-.0000386	.0010826
ARMA							
	ar						
	L1.	.1477242	.0102897	14.36	0.000	.1275566	.1678917
ARCH							
	tarch						
	L1.	.0456408	.0035855	12.73	0.000	.0386134	.0526683
	garch						
	L1.	.9731957	.0022938	424.27	0.000	.9686999	.9776914
	_cons	1.35e-06	2.92e-07	4.62	0.000	7.76e-07	1.92e-06

ARCH-in-Mean

- Pozwala on uwzględnić wpływ wariancji na wartość oczekiwaną

$$y_t = X_t\beta + \delta\sigma_t^2 + \varepsilon_t$$

$$\varepsilon_t = u_t\sigma_t$$

$$\sigma_t^2 = \theta_0 + \theta_1\varepsilon_{t-1} + \dots + \theta_q\varepsilon_{t-q}$$

Diagnostyka

- Diagnostyka nie odbiega od standardowej diagnostyki modelu regresji

Diagnostyka

- Diagnostyka nie odbiega od standardowej diagnostyki modelu regresji
- Równanie średniej polega standardowej procedurze diagnostycznej

Diagnostyka

- Diagnostyka nie odbiega od standardowej diagnostyki modelu regresji
- Równanie średniej polega standardowej procedurze diagnostycznej
- Testem poprawności specyfikacji modelu jest test normalności reszt oraz zbadanie występowania efektów ARCH w resztach

- Prawdopodobieństwo poniesienia wysokiej straty

- Prawdopodobieństwo poniesienia wysokiej straty

Wartość narażona na ryzyko

Dla danego poziomu prawdopodobieństwa α jest to strata jaka może się zdarzyć z prawdopodobieństwem α

$$Pr(L_j > J_t) = 1 - Pr(L_j < J_t) = 1 - F(J_t) = \alpha$$

J_t jest wartością narażoną na ryzyko.

VaR dla WIG

- Stopa zwrotu jest dana przez

$$r_t = \ln(P_t) - \ln(P_{t-1})$$

VaR dla WIG

- Stopa zwrotu jest dana przez

$$r_t = \ln(P_t) - \ln(P_{t-1})$$

- Bank inwestuje Q jednostek

VaR dla WIG

- Stopa zwrotu jest dana przez

$$r_t = \ln(P_t) - \ln(P_{t-1})$$

- Bank inwestuje Q jednostek
- Zmiana ceny funduszu wynosi

$$P_t - P_{t-1} = P_{t-1}[\exp(r_t) - 1]$$

VaR dla WIG

- Stopa zwrotu jest dana przez

$$r_t = \ln(P_t) - \ln(P_{t-1})$$

- Bank inwestuje Q jednostek
- Zmiana ceny funduszu wynosi

$$P_t - P_{t-1} = P_{t-1}[\exp(r_t) - 1]$$

- Zatem wynik inwestycji netto jest równy

$$L_t = Q\Delta P_t = QP_{t-1}[\exp(r_t) - 1]$$

VaR dla WIG

- VaR wynosi

$$Pr(L_j < J_t) = Pr(QP_{t-1}[\exp(r_t) - 1] < J_t)$$

$$Pr(L_j < J_t) = Pr(r_t < \underbrace{\ln\left(1 + \frac{J_t}{QP_{t-1}}\right)}_{k_t})$$

VaR dla WIG

- VaR wynosi

$$Pr(L_j < J_t) = Pr(QP_{t-1}[\exp(r_t) - 1] < J_t)$$

$$Pr(L_j < J_t) = Pr(r_t < \underbrace{\ln\left(1 + \frac{J_t}{QP_{t-1}}\right)}_{k_t})$$

- Wystarczy znaleźć k_t

$$Pr(r_t < k_t) = Pr\left(\frac{r_t - \mu_t}{\sigma_t} < \frac{k_t - \mu_t}{\sigma_t}\right) = Pr(u_t < \frac{k_t - \mu_t}{\sigma_t})$$

$$Pr(r_t < k_t) = Pr(u_t < \frac{k_t - \mu_t}{\sigma_t}) = F\left(\frac{k_t - \mu_t}{\sigma_t}\right) = 1 - \alpha$$

VaR dla WIG

- VaR wynosi

$$Pr(L_j < J_t) = Pr(QP_{t-1}[\exp(r_t) - 1] < J_t)$$

$$Pr(L_j < J_t) = Pr(r_t < \underbrace{\ln\left(1 + \frac{J_t}{QP_{t-1}}\right)}_{k_t})$$

- Wystarczy znaleźć k_t

$$Pr(r_t < k_t) = Pr\left(\frac{r_t - \mu_t}{\sigma_t} < \frac{k_t - \mu_t}{\sigma_t}\right) = Pr(u_t < \frac{k_t - \mu_t}{\sigma_t})$$

$$Pr(r_t < k_t) = Pr(u_t < \frac{k_t - \mu_t}{\sigma_t}) = F\left(\frac{k_t - \mu_t}{\sigma_t}\right) = 1 - \alpha$$

- Zatem

$$k_t = \mu_t + F^{-1}(1 - \alpha)\sigma_t$$