

Warsztaty 7: Deepfake i oszustwa AI

Checklista czerwonych flag

Używaj tej listy, gdy widzisz obraz, film, reklamę, wiadomość albo słyszysz głos, który prosi o szybkie działanie.

1. PRESJA

Uwaga, jeśli pojawia się:

- [] zrob to teraz
- [] ostatnia szansa
- [] nie rozłączaj się
- [] nikomu nie mów
- [] usun, zanim zniknie
- [] wyslij szybko
- [] masz tylko kilka minut
- [] strach, wstyd, gniew albo wzruszenie

Zasada:

Presja czasu nie jest dowodem prawdziwości.
Presja czasu jest powodem, żeby zwolnić.

2. KOD, LINK, DANE, PIENIADZE

Zatrzymaj się, jeśli ktoś prosi o:

- [] kod BLIK
- [] przelew
- [] dane karty
- [] hasło albo login
- [] zainstalowanie aplikacji
- [] kliknięcie w link
- [] zdjęcie dokumentu
- [] dane osobowe
- [] szybka wpłata

Zasada:

Głos, film, reklama ani wiadomość nie wystarczają do podania kodu, danych albo pieniędzy.

3. PODSZYCIE

Sprawdź, czy ktoś nie udaje:

- [] osoby bliskiej
- [] znajomego
- [] pracownika banku
- [] urzędnika
- [] policjanta
- [] lekarza albo eksperta
- [] osoby publicznej
- [] znanej organizacji

Zasada:

Tożsamość sprawdzam drugim kanałem, najlepiej takim, który znam z wcześniej.

4. BRAK ZRODLA

Czerwona flaga:

- [] brak oficjalnej strony
- [] dziwny albo podobny adres strony
- [] brak daty
- [] brak miejsca
- [] brak pelnego nagrania
- [] brak regulaminu
- [] brak danych organizatora
- [] brak niezaleznego potwierdzenia

Zasada:

Jesli nie moze sprawdzic zrodla, nie klikam, nie place i nie przesyłam dalej.

5. OBRAZ, FILM, GLOS

Mozliwe sygnaly:

- [] ruch ust nie pasuje do glosu
- [] glos jest plaski albo zbyt rowny
- [] brakuje naturalnych pauz
- [] akcent albo rytm jest dziwny
- [] gesty nie pasuja do tresci
- [] tlo wyglada nienaturalnie
- [] obraz jest zbyt emocjonalny i bez kontekstu
- [] znana osoba mowi cos, co nie pasuje do jej zwyklego sposobu wypowiedzi

Zasada:

Sygnal techniczny pomaga, ale nie wystarcza.

Najwazniejsze jest: czego ta tresc ode mnie chce?

6. RYTUAL STOP

1. STOP

Nie dzialam od razu.

2. ZRODLO

Sprawdzam, skad to przyszlo.

3. DRUGI KANAL

Oddzwaniem na znany numer albo wchodze samodzielnie na oficjalna strone.

4. KOD/LINK/PIENIADZE

Nie podaje pod presja.

5. DECYZJA

Decyduje po sprawdzeniu.

7. GDY KTOS JUZ KLIKNAL ALBO PODAL DANE

Nie zaczynam od wstydu. Zatrzymuje szkody.

- [] zapisuje link, numer, godzine i zrzut ekranu
- [] nie kasuje wiadomosci ani historii polaczenia
- [] kontaktuje bank, urzad albo organizacje samodzielnie znalezionym kanalem
- [] blokuje karte albo konto, jesli pojawily sie pieniadze lub dane
- [] zmieniam haslo, jesli moglo zostac ujawnione

[] zgłaszam podejrzaną treść

Zasada:

Szybkie zgłoszenie jest lepsze niż idealny opis sytuacji.

8. GDZIE SPRAWDZAC I ZGLASZAC

Ważne adresy i kanały:

- CERT Polska: <https://incydent.cert.pl/>
- Podejrzaną SMS z linkiem: przeslij na numer 8080
- Kontakt CERT Polska: <https://cert.pl/kontakt/>
- NASK o rozpoznawaniu deepfake: <https://nask.pl/>
- Policja o oszustwach BLIK i AI: <https://policja.pl/>
- CEBRF KNF o fałszywych inwestycjach: <https://cebrf.knf.gov.pl/>

Zasada:

Adres wpisuje samodzielnie albo wybieram ze znanej zakładki.

Nie korzystam z linku przesłanego w podejrzanej wiadomości.

ZDANIE NA KONIEC

Nie muszę wiedzieć od razu, czy to deepfake.

Mam zatrzymać akcję i sprawdzić źródło.