

SZKOŁA GŁÓWNA GOSPODARSTWA WIEJSKIEGO W WARSZAWIE

WYDZIAŁ ZASTOSOWAŃ INFORMATYKI I MATEMATYKI

KATEDRA INFORMATYKI

ROZPRAWA DOKTORSKA

Model integracji danych dla prognoz eksperckich w informatycznych systemach zarządzania ryzykiem

Autor:

Mgr Marek Karwański

Promotor pracy:

Prof. Arkadiusz Orłowski

Warszawa 2012

SPIS TREŚCI

1.	Wprowadzenie	5
1.1.	Motywacja i cel pracy	5
1.2.	Podstawowe pojęcia systemu pomiaru ryzyka operacyjnego	7
2.	Przegląd elementów systemu wspomagającego zarządzanie ryzykiem operacyjnym	10
2.1.	Model danych do pomiaru ryzyka operacyjnego	10
2.2.	Modele analityczne	11
2.3.	Modele kwantyfikacji opinii eksperckich i budowy scenariuszy	12
2.4.	Dotychczasowe prace nad ryzykiem operacyjnym na podstawie literatury	15
3.	Przegląd metodologii używanych w zarządzaniu ryzykiem operacyjnym.	17
3.1.	Zarządzanie ryzykiem w instytucjach finansowych – funkcja biznesowa	17
3.2.	Utrzymanie adekwatności kapitałowej	17
3.3.	Ograniczenie ekspozycji na ryzyko	18
3.4.	Optymalizacja ekspozycji na ryzyko	18
3.5.	Ryzyko operacyjne	19
3.6.	Zasady należytego zarządzania dla ryzyka operacyjnego	19
4.	Elementy systemu pomiaru ryzyka operacyjnego	22
4.1.	Ogólny opis Systemu wspierającego zarządzanie ryzykiem operacyjnym	22
4.2.	Architektura rozwiązania	23
4.3.	Opis modułów Systemu Wspierającego Zarządzanie Ryzykiem Operacyjnym.	23
5.	Model danych do pomiaru ryzyka operacyjnego w ramach systemu S-OR.....	43
5.1.	Data Mart systemu S-OR	43
5.2.	Moduł Danych Wewnętrznych	46
5.3.	Moduł Danych Samooceny i Scenariuszy	46
5.4.	Moduł Danych Środowiska Biznesowego KRI	47
5.5.	Moduł danych pomocniczych – wymiary i słowniki	48
5.6.	Moduł Danych Systemu Ubezpieczeń i Monitorowania Działania Zaradczych	49
5.7.	Data Mart - opis procesów systemu S-OR	50
5.8.	Procesy KRI.	52
5.9.	Procesy RCSA - kwantyfikacja prognoz i opinii eksperckich	61
5.10.	Procesy pomiaru ryzyka VaR metodą LDA	65
5.11.	Detaliczne informacje o strukturze tabel VaR.	75
6.	Opis procesu: zarządzanie ryzykiem i samoocena RCSA	79
6.1.	Wprowadzenie	79
6.2.	Proces samooceny	81
6.3.	Scenariusze w ramach metodologii sbAMA	90
6.4.	Wykorzystanie opinii ekspertów do budowy modelu ryzyka operacyjnego	92
6.5.	Integracja LDA i sbAMA	94
6.6.	Techniki RCSA	95
6.7.	Pozyskiwanie wiedzy od ekspertów	108
7.	Kwantyfikacja ekspertyz - metoda Duration	113
7.1.	Wstęp	113
7.2.	Metoda Duration	113
7.3.	Metody kwantyfikacji i agregowania wiedzy eksperckiej – łączenie opinii ekspertów	116
7.4.	Modele matematyczne	119
7.5.	Model Supra-Bayes'a w ryzyku operacyjnym.	127
7.6.	Modele dla zagregowanej straty – wykorzystanie scenariuszy do budowy modeli częstości i dotkliwości. ...	130
8.	Metoda zbiorów rozmytych	139
8.1.	Wprowadzenie	139
8.2.	Reprezentacja ryzyka	140
8.3.	Reprezentacja ryzyka przez rozmyty system ekspertowy	143
8.4.	Analiza i wnioskowanie	144
9.	Kalibracja modelu szacowania ryzyka w oparciu o prognozy ekspertów.	146
9.1.	Prowadzenie procesu samooceny i pomiar ryzyka.	146
9.2.	Scenariusze i kwestionariusze	147
9.3.	Ocena jakościowa ryzyka operacyjnego dla aplikacji IT	147
9.4.	Ocena ilościowa ryzyka operacyjnego dla aplikacji IT	148
9.5.	Przeprowadzanie procesu samooceny	149

9.6.	Dane źródłowe i wyniki analiz	149
9.7.	Obliczenia dla modelu Supra-Bayes.....	157
10.	Podsumowanie	161
11.	Literatura.....	167

1. Wprowadzenie

1.1. Motywacja i cel pracy

W dzisiejszych, coraz bardziej rygorystycznych regulacjach, firmy są pod presją instytucji nadzorczych, wymuszających lepsze zarządzanie ryzykiem operacyjnym w celu powstrzymania strat oraz alokacji kapitału ekonomicznego zgodnie z wymogami regulacyjnymi. W ostatnich latach opublikowane zostały przepisy prawne takie jak: dyrektywy UE w sprawie wymogów kapitałowych, uchwały KNF transponujące postanowienia: Bazylei II, dyrektywy Solvency II i warunków wykonywania działalności ubezpieczeniowej w Polsce w ramach Wyłącalności II, Ustawa o Finansach Publicznych, przepisy dotyczące kontroli wewnętrznej nad sprawozdawczością finansową Sarbanes-Oxley, przepisy o Równym Traktowaniu Klientów (Treating Customers Fairly), zasady w sprawie kontroli w zakresie informacji i związanych z nimi technologiami COBIT, oraz norm ISO17799 / ISO 27002. Stawia to bardzo ostre wymagania przed systemami IT wspierającymi zarządzanie ryzykiem (Deloitte 2007).

Mimo dużej liczby założeń prawnych i organizacyjnych definiowanych przez regulatorów okazuje się, że rozwiązania technologiczne oraz metodologia są podobne w firmach o różnym profilu działalności, zarówno w instytucjach finansowych: bankach i zakładach ubezpieczeniowych, jak i niefinansowych: przedsiębiorstwach produkcyjnych i jednostkach administracji terenowej. Różnice pojawiają się dopiero w konkretnych realizacjach i dotyczą konfiguracji dopasowanej do obszaru prawnych uregulowań biznesowych. Dlatego, wydaje się bardzo ważne, opracowanie uniwersalnych modeli danych i metod analitycznych mających zastosowanie w zarządzaniu ryzykiem operacyjnym (Tripp 2004).

System wspomagający zarządzanie ryzykiem operacyjnym musi spełniać dwie podstawowe funkcje:

- po pierwsze musi służyć do kontroli procesów i praktyk operacyjnych,
- po drugie powinien pozwolić na ilościowy pomiar ryzyka w celu określenia niezbędnych zabezpieczeń finansowych.

Powstało wiele rozwiązań, oferowanych na rynku komercyjnym, pozwalających na budowę i wdrożenie systemów IT. Niektóre z nich są rozwiązaniami kompleksowymi inne dotyczą tylko pewnych fragmentów.

Na potrzeby niniejszej pracy przeanalizowano kilka systemów wspierających zarządzanie ryzykiem:

- OpRisk Management System firmy SAS
- Operational Risk Framework firmy Chase Cooper
- Operational Risk Solution firmy List Group
- Operational Risk Suite firmy RCS
- Operational Risk Software firmy Optial
- Reveleus Operational Risk Solution firmy Oracle

Poniższy diagram tzw. "Gartner Magic Quadrant for Operational Risk Management" prezentuje najbardziej popularne produkty w rozbiciu na ich cechy: stopień pokrycia wymagań biznesowych (*completeness of vision*) oraz właściwości technologiczne (*ability to execute*).



Rysunek 1. Diagram "Gartner Magic Quadrant for Operational Risk Management". Źródło: Gartner, Inc., 2010

Budowa powyższych systemów oparta była na podziale funkcjonalnym realizowanym w modułach opisanych w powyżej, chociaż w niektórych rozwiązaniach występowały tylko wybrane moduły. Wszędzie dał się zauważyć wyraźny podział na część systemu związaną ze zbieraniem danych wewnętrznych i monitorowaniem środowiska operacyjnego oraz część analityczną służącą do wyliczenia ryzyka dla celów biznesowych.

Podstawowe wnioski wyciągnięte na podstawie przeglądu komercyjnych systemów mówią, że funkcje systemu muszą bazować na doświadczeniach historycznych oraz prognozach. W praktyce, wykorzystuje się liczne źródła danych, zarówno „twarde” dane historyczne zbierane wewnątrz przedsiębiorstwa, historyczne dane publikowane przez podobne firmy, jak również prognozy uzyskiwane od ekspertów. Szczególnie istotne jest ostatnie źródło danych, gdyż pozwala ono na szybkie pozyskanie informacji potrzebnych np. do kalibracji modeli analitycznych. Czas gromadzenia odpowiedniej bazy danych jest rzędu jednego roku, co w porównaniu z czasem gromadzenia danych historycznych, który z reguły wynosi pięć i więcej lat, czyni opinie ekspertów bardzo atrakcyjnymi. Wadą danych opartych na opinii ekspertów jest mała dokładność i podatność na liczne obciążenia.

W związku z tym autor niniejszej pracy przyjął za cel opracowanie modeli zarówno gromadzenia danych historycznych i eksperckich jak również modelu analitycznego pozwalającego na bardziej dokładne szacowanie wyników biznesowych w oparciu o opinie eksperckie.

Pierwszym celem pracy jest propozycja modelu bazy danych historycznych, która zapewnia wysoką jakość danych wykorzystywanych w modelach analitycznych.

Drugim celem pracy jest analiza sposobów zbierania danych eksperckich oraz modeli liczenia ryzyka i propozycja modyfikacji mająca na celu polepszenie prognoz uzyskiwanych na ich podstawie. Analizy omawiane są w powiązaniu z projektami systemów informacyjnych wspierającymi zarządzanie ryzykiem operacyjnym wdrażanymi w polskich bankach.

Celem pracy jest budowa logicznego modelu bazy danych systemu wspomagającego zarządzanie ryzykiem operacyjnym z uwzględnieniem nowych metod kwantyfikacji wiedzy eksperckiej. Obok metod, które już stosowane są w praktyce autor proponuje modyfikacje mogące poprawić dokładność i stabilność modeli analitycznych pomiaru ryzyka.

Praca zawiera następujące całkowicie nowe elementy:

- **Projekt logiczny Data Martu** służącego do zbierania i gromadzenia danych, w ramach funkcjonalności systemu wspomagającego zarządzanie ryzykiem operacyjnym S-OR oraz wybranych metod analitycznych, wykorzystywanych obecnie do pomiaru ryzyka operacyjnego w instytucjach finansowych i niefinansowych;
- **Propozycję modyfikacji algorytmów analiz danych eksperckich** zbieranych w ramach procesu oceny ryzyka, które mogłyby być wykorzystane nie tylko w warunkach badawczych, ale również w praktyce.

1.2. Podstawowe pojęcia systemu pomiaru ryzyka operacyjnego

Definicja ryzyka operacyjnego, przyjmowana powszechnie, zgodna jest z określeniem Komitetu Bazylejskiego ds. Nadzoru Bankowego jako "ryzyko straty wynikającej z niedostosowania lub zawodności wewnętrznych procesów, ludzi i systemów lub ze zdarzeń zewnętrznych". Instytucje finansowe starają się rozwijać systemy informatyczne wspomagające to podejście do pomiaru, oceny, monitorowania i zarządzania ryzykiem operacyjnym. Systemy pomiaru Ryzyka Operacyjnego muszą zawierać pewne zasadnicze elementy – moduły. Do elementów tych należą: dane wewnętrzne i zewnętrzne, analiza scenariuszy wariantowych, czynniki odzwierciedlające otoczenie gospodarcze oraz systemy kontroli wewnętrznej.

Podstawowe elementy systemu wspomagającego zarządzanie ryzykiem:

- **Baza strat** – Loss Data Collection (LCD) – rejestr informacji o zdarzeniach i stratach, umożliwiający monitoring poprawności i kompletności informacji;
- **Kluczowe wskaźniki ryzyka** – Key Risk Indicators (KRI) – definicja, pomiar i przechowywanie wszystkich kluczowych wskaźników otoczenia ekonomicznego umożliwiającego powiązanie pomiaru ryzyka z czynnikami zewnętrznymi i wewnętrznymi;
- **Scenariusze ryzyka** - szablony do pomiaru wpływu czynników ryzyka i powiązanych z nimi środków zapobiegawczych budowane w oparciu o dane historyczne lub na podstawie opinii ekspertów;

- **Kontrola** – Control Assessment (CA) – zespół środków i narzędzi pozwalających na ocenę skuteczności działania systemu zarządzania w tym zbieranie danych o naruszeniach procedur i przeciwdziałaniu powstawania strat;
- **Prognozy eksperckie** – Risk Control and Self Assessment (RCSA) – zbieranie danych subiektywnych o procesach na podstawie opinii eksperckich oraz ich kwantyfikacja;
- **Skalowanie** - integracja wewnętrznych i zewnętrznych baz danych o stratach, jak również prognoz eksperckich;
- **Audyt** – zespół środków i narzędzi służących do generowania raportów z kontroli, rejestracja wniosków dotyczących kontroli, tworzenie działań i śledzenie postępów;
- **Zarządzanie ciągłością działań** – Business Continuation Plans (BCP) - określenie potencjalnego wpływu na biznes działań zarządczych i zapewnienie prawidłowego działania systemu w części prewencyjnej ;
- **Modelowanie ilościowe** - różnorodne modele ekonometryczne i statystyczne;
- **Kontrola zgodności** – Regulatory Compliance (RC) – badanie i ocena poprawności procesów w świetle wymogów prawnych;
- **Business Intelligence (BI)** - zaawansowane raportowanie i analiza danych.

Banki wdrażając zaawansowane metody pomiaru ryzyka operacyjnego liczą na:

- Obniżenie wymogów kapitałowych czyli odpowiednich rezerw, wg szacunków dokonywanych w dwóch polskich bankach może chodzić nawet o wartości rzędu 20%
- Uzyskanie pomiaru kosztów ryzyka możliwych do włączenia do systemów rentownościowych


O ile drugi z tych celów, nie jest związany z formalnymi wymaganiami i może prowadzić do rozwoju systemów ocenianych jedynie skutecznością, jak to ma miejsce w obszarze wsparcia sprzedaży (Customer Relationship Management), o tyle pierwszy cel wymaga spełnienia wielu warunków. W celu monitorowania ryzyka nadzorca określił bardzo rygorystyczne warunki: miara ryzyka operacyjnego musi obejmować potencjalnie dotkliwe wypadki skrajne, osiągając normę pewności porównywalną z przedziałem ufności na poziomie 99.9% przez okres jednego roku.

System pomiaru ryzyka operacyjnego banku wykorzystuje wiele źródeł danych takich jak:

- dane wewnętrzne
- dane zewnętrzne,
- dane z analiz scenariuszy wariantowych,
- czynniki wewnętrzne i zewnętrzne odzwierciedlające otoczenie gospodarcze
- dane generowane przez systemy ograniczania ryzyka i kontroli wewnętrznej.

Podyktowane jest to zapotrzebowaniem na oceny dotkliwości i częstości występowania zdarzeń powodujących straty z bardzo szerokiego zakresu. Z jednej strony ustalany jest minimalny próg wartości strat, który odcina zdarzenia, dla których koszt i możliwość rejestracji przestają być realne z punktu widzenia biznesu, z drugiej strony wymagane są szacunki strat mogących wystąpić średnio raz na 1000 lat.

Na poniższym rysunku zaznaczone zostały relacje pomiędzy różnymi komponentami systemu z punktu widzenia przetwarzania zdarzeń



Rysunek 2. Schemat „pokrycia” zakresu danych przez różne źródła. Źródło opracowanie własne

Właściwe zaplanowanie baz dla poszczególnych źródeł danych jest bardzo ważnym elementem możliwości implementacji spójnego systemu analitycznego.

2. Przegląd elementów systemu wspomagającego zarządzanie ryzykiem operacyjnym

2.1. Model danych do pomiaru ryzyka operacyjnego

Podstawową cechą modelu danych w zarządzaniu ryzykiem operacyjnym jest to, że składa się on z dwóch części: bazy operacyjnej typu workflow oraz repozytorium w postaci hurtowni danych lub tzw. Data Martu.

W niniejszej pracy zaproponowany zostanie model danych typu Data Mart oraz funkcje łącznie z diagramami ULM typu „przypadki użycia”, które muszą być spełnione aby mógł być wykorzystany do celów analitycznych.

Krótką charakterystyka bazy strat - Workflow

Baza operacyjna służy do zbierania danych o różnych zdarzeniach mogących prowadzić do powstania strat. Proces zbierania danych polega na rejestracji informacji bezpośrednio do systemu przez pracowników pełniących odpowiednie role, rzadziej gromadzi się informacje poprzez ich import z innych systemów IT. W procesie zbierania danych uczestniczy bardzo wiele pracowników, np. w jednym z dużych polskich banków liczba pracowników zaangażowanych w zbieraniu danych operacyjnych była szacowana na około 1 500. Z tego powodu system gromadzenia danych musi być odpowiednio przygotowany – najczęściej budowany jest w oparciu o architekturę workflow.

Kluczowe cechy systemu gromadzenia danych typu workflow

- Zbieranie informacji o zdarzeniach i stratach operacyjnych np. poprzez interfejs intranetowy, dane wprowadzane przez pracowników instytucji zgłaszających zdarzenia operacyjne,
- Pobieranie informacji o zdarzeniach operacyjnych z systemów IT – automatyczny import z istniejących źródeł danych np. z systemów księgowych, systemów podanych w zapytaniu ofertowym,

Obsługa pełnego procesu przetwarzania zdarzeń operacyjnych musi uwzględniać następujące procedury:

- Identyfikacji zdarzenia/straty – bardzo istotne jest rozróżnienie zdarzenia i straty ponieważ mogą występować przypadki, gdy do jednego zdarzenia trzeba przypisać wiele strat. Przykładem może być brak prądu w ciągu kilkunastu minut.
- Akceptowania zdarzenia/straty w kontekście jednostki – wprowadzanie danych odbywać się musi z wykorzystaniem procedur walidacyjnych
- Procesu badania i wyceny straty,
- Procesu odzyskiwania strat z uwzględnieniem kosztów - tzw. mitygacja
- Podziału odpowiedzialności i kosztów związanych ze zdarzeniem,
- Księgowania poszczególnych przepływów związanych ze stratami,
- Administracja systemem – tworzenie listy zdarzeń, wyszukiwanie, filtrowanie,

Niektóre ryzyka wymagają specjalnego podejścia do ich wyceny. Dotyczy to szczególnie zdarzeń, które mają wpływ na wiele procesów i prowadzą do dużej liczby większych lub mniejszych strat. Kwantyfikacja takich zdarzeń opierana jest najczęściej na podejściu scoringowym. Po wyliczeniu strat, związanych z takimi ryzykami, dobrą praktyką jest ustalenie korekty dla konkretnego zdarzenia bazującej na uwzględnieniu procesów kontrolnych zmieniających się pod wpływem doświadczeń historycznych.

Krótką charakterystyka bazy strat – Data Mart

Dane wejściowe do Systemu wspomagającego zarządzanie Ryzykiem Operacyjnym są przygotowane przez moduł obsługi danych, który oprócz pobrania potrzebnych danych (poszczególne kategorie wartości strat w wymaganym podziale szczegółowości) dokonuje także ich wzbogacenia o wymagane w dalszym etapie przetwarzania informacje.

Data Mart jest fizyczną realizacją modelu danych. Zapisane są w nim zarówno struktury jak i powiązania pomiędzy tymi strukturami. Zawiera wszystkie definicje i połączenia do fizycznych struktur oraz procedur.

Data Mart obejmuje:

- Struktury danych, które określają formaty i adresy przechowywania zarówno danych, transakcyjnych jak i danych pomocniczych w postaci rejestrów i słowników.
- Realizację procesów ETL - procesy dostępu i transformacji danych z systemów informatycznych Banku, a także pobieranie niezbędnych danych w sposób interakcyjny.
- Kontrolę i sterowanie procesami analitycznymi, w tym przechowywanie informacji umożliwiającej stworzenie słowników.

2.2. Modele analityczne

Typy modeli wykorzystywanych do liczenia ryzyka operacyjnego:

- modele probabilistyczne oparte na rozkładach prawdopodobieństw – tzw. LDA (Loss Distribution Approach),
- modele scoringowe oparte na klasyfikowaniu zdarzeń do różnych klas na podstawie analizy atrybutów tych zdarzeń.

Oba typy różnią się zarówno sposobem zbierania danych jak i metodologią liczenia ryzyka, która musi uwzględniać wymogi prawne zawarte w odpowiednich ustawach, nie mogą być stosowane równolegle.

Proces budowy modeli zostanie poprzedzony omówieniem typowych metod analizy wartości zagrożonej (Value at Risk) zarówno modeli analitycznych jak i opartych na symulacjach Monte Carlo.

Ważne zadanie przypada modelom skalowania poszczególnych źródeł danych w celu ich połączenia (Baud 2002). Łączenie informacji uzyskanej np. ze scenariuszy i danych wewnętrznych oraz zewnętrznych w ramach modeli LDA można przeprowadzić na dwa sposoby:

- ex post – czyli przeprowadzić modelowanie oddzielnie i połączyć wyniki na poziomie zagregowanym,
- ex ante – włączyć informacje o parametrach rozkładów do modeli częstości i dotkliwości zdarzeń na etapie procedur analitycznych.

Warto zwrócić uwagę, że proces skalowania obejmuje:

- skalowanie danych mające na celu standaryzację danych o stratach i stosowane jest głównie przy korzystaniu z danych zewnętrznych, można tu sięgnąć po zaawansowane metody korzystające z procedur tzw. importance sampling lub oparte na ilorazie wiarygodności,
- skalowanie parametrów rozkładów w celu włączenia zmian środowiska biznesowego do obliczania prognoz ryzyka.

2.3. Modele kwantyfikacji opinii eksperckich i budowy scenariuszy

W literaturze omawiane są różne podejścia do kwantyfikacji wiedzy eksperckiej na temat częstości i skutków różnych zdarzeń operacyjnych. Proces ten polega zazwyczaj na przełożeniu wiedzy i opinii eksperta na odpowiedni rozkład prawdopodobieństwa. Ponieważ często brak jest możliwości porównania opinii z „twardymi” danymi historycznymi, trzeba stosować różnego rodzaju uproszczenia i przybliżenia, np. jednym z problemów jest identyfikacja błędów wynikająca z „wiedzy” eksperta oraz z metod przełożenia tej wiedzy na model probabilistyczny. Różne strategie pozyskania wiedzy eksperckiej obciążone są różnymi obciążeniami.

W przypadku budowy scenariuszy dla ryzyka operacyjnego strategia zbierania i analizy danych jest szczególnie istotna ponieważ często dotyczy zdarzeń rzadkich. W przypadku analiz ilościowych konieczne są rozbudowane procedury formalne, gdyż intuicyjne szacowanie parametrów dotyczące np. wyższych momentów rozkładów jest obciążone dużym błędem i praktycznie nie powinno być stosowane. Jeżeli dodać do tego obciążenia związane z aspektem psychologicznym występującym podczas zbierania danych jak np. obecność uznanego autorytetu lub przełożonego, widać, że sama organizacja procesu pozyskania danych powinna być bardzo dokładnie zaplanowana i przeprowadzona.

W pracy zaprezentowana zostanie ocena stosowania różnych metodologii oraz zostanie zaproponowana wybrana metoda pozwalająca uwzględnić zarówno realia spotykane w bankach jak i wytyczne znajdujące się w regulacjach prawnych.

Krótką charakterystyka zbierania opinii eksperckich – analiza scenariuszowa

Celem analiz scenariuszowych jest gromadzenie danych o zdarzeniach przyszłych na podstawie opinii eksperckich. Obszary podlegające analizie np. kategorie ryzyk, jednostki organizacyjne czy procesy identyfikowane są okresowo, a następnie uzupełniane w trybie zarządzania zmianami, wynikającymi np. z nowych produktów, zmiany struktury organizacyjnej itp.

Proces wdrażania metody RCSA powinien zostać podzielony na dwie części:

- Identyfikację – określenie obszarów, zdarzeń istotnych,
- Pomiar – oszacowanie ilościowe poszczególnych zdarzeń na poziom ryzyka.

Identyfikacja ryzyk może zostać przeprowadzona w oparciu o strukturę organizacyjną lub podział na procesy. Bardziej precyzyjny jest drugi sposób ze względu na możliwość włączenia do identyfikacji „właścicieli procesów”. Ważne jest aby metodyka elicytacji czyli pozyskiwania wiedzy eksperckiej była przejrzysta i spójna (Ruhm 2005).

Stosuje się dwa podejścia:

- Metoda ankietowa,
- Metoda warsztatowa .

W obu przypadkach stosuje się specjalnie przygotowane kwestionariusze, różnica polega na metodzie uzgodnienia wyników – przeprowadza się je metodami statystyki opisowej lub podczas wspólnego zebrania.

Ogólne zalecenia dotyczące budowy kwestionariuszy:

- ekspert powinien dokonać oceny istotności zdarzenia – pomiar jakościowy,
- ekspert powinien dodatkowo opisać rozkład prawdopodobieństwa częstości i dotkliwości wg odpowiednich wzorców,
- ekspert powinien dokładnie określić swój związek ze zdarzeniem, który może wpłynąć na ocenę,
- powinno przeprowadzić się szkolenia „kalibrujące” grupę ekspertów np. poprzez przekazanie im materiałów z danymi historycznymi itp.,
- trzeba dokumentować nie tylko wynik uzyskany od eksperta ale również dodatkowe informacje (np. uwagi itp.).

Podczas przeprowadzania procesu zbierania danych przy pomocy samooceny warto zwrócić uwagę na używane heurystyki wnioskowania, które mogą powodować różne obciążenia wyników. Wybór heurystyki może być ustalony podczas wstępnej „kalibracji” uczestników samooceny.

Najpopularniejsze heurystyki to:

- ocena poprzez reprezentatywność – ekspert ocenia prawdopodobieństwo, że zdarzenie należy do pewnej kategorii na podstawie cech charakterystycznych (pewne stereotypy),
- ocena poprzez dostępność – ekspert ocenia częstość na podstawie własnych doświadczeń poprzez np. wymienienie okazji do pojawienia się błędu,

- ocena poprzez wstępne zakotwiczenie i korektę – ekspert ocenia wstępnie parametry zjawiska – właściwości wyjściowe czasami podawane podczas szkolenia - a następnie zmienia swoje oszacowanie próbując znaleźć rozwiązanie „w okolicy wstępnej oceny”.

W praktyce w wyniku przeprowadzenia analizy samooceny powstaje raport. Wyniki tego raportu powinny być prezentowane w postaci jakościowej i ilościowej.

Metody zbierania danych zarówno w postaci ankietowej jak i warsztatowej można klasyfikować ze względu na wzorce zbierania danych oraz sposób modelowania rozkładu (bezpośredni lub pośredni).

Do zbierania informacji w procesie samooceny używane są najczęściej trzy wzorce kwestionariuszy:

- Podejście percentylowe – jako wyniki uzyskuje się wartości strat odpowiadające wybranym percentylom (np. 50%, 95%, 99%).
- Podejście interwałowe – wyniki uzyskiwane są jako przedziały dotkliwości i częstości dla serii różnych zakresów strat.
- Podejście indywidualne – wybranym wartościom strat przypisywane są odpowiednie prawdopodobieństwa.

Zaleca się szacowanie ilościowych wyników samooceny w postaci prostych rozkładów parametrycznych. W zależności od metody zbierania danych stosuje się różne modele statystyczne. Najczęściej oparte są na rozkładach parametrycznych jak np. log-normalnym, gdzie szacowanie polega na ocenie parametrów rozkładu, wykorzystuje się metody estymacji: od prostych podstawień (estymatory plug-in), poprzez metody najmniejszych kwadratów, do metod największej wiarygodności w modelach z danymi obciążeniami.

Estymacja parametrów rozkładów zależy również od sposobu modelowania rozkładu. Można wyróżnić:

- Metodę bezpośrednią - na podstawie rozkładu prawdopodobieństwa w postaci histogramowej – model wybierany jest z zadanych rodzin na podstawie różnego rodzaju „miar odległości”,
- Metodę pośrednią - na podstawie estymacji czasu (duration) pojawienia się zdarzeń powyżej wybranych progów strat – model budowany jest w oparciu o procesy stochastyczne.

Scenariusze mogą odnosić się do pojedynczych zdarzeń lub grup zdarzeń, które dopiero na etapie symulacji wyniki łączone są w odpowiednie wiązki (Folpmers 2008). Trzeba zwrócić uwagę, że nie ma dotychczas sugestii dotyczących uwzględnienia „korelacji” pomiędzy podobnymi scenariuszami z tego względu liczba scenariuszy w ramach jednego procesu nie powinna być zbyt duża co oznacza, że nie powinna przekraczać granicy 10-15. Natomiast łączna liczba scenariuszy dla różnych linii biznesowych może przekroczyć liczbę 100.

Do każdego scenariusza trzeba przypisać wagę względną odpowiedzialną za tzw. „postawę ostrożnościową” uczestników ankiety. Skalowanie wyników samooceny jest bardzo istotnym elementem w przypadku agregacji wyników uzyskiwanych dla danych wewnętrznych (i ewentualnie zewnętrznych) oraz scenariuszowych.

2.4. Dotychczasowe prace nad ryzykiem operacyjnym na podstawie literatury

Regulacje prawne, choć nie narzucają konkretnych rozwiązań, przyczyniły się do rozwoju systemów analitycznych wspierających zarządzanie ryzykiem. (Cruz 2002) opisuje różne metody analityczne wykorzystywane do obliczenia ryzyka operacyjnego z uwzględnieniem specyfiki ich stosowania w instytucjach finansowych (Kilavuka 2008). Podobne porównanie podejść analitycznych w ramach metodologii: IMA i LDA, prezentuje (Shevchenko 2009). Z kolei (Berger 1985) (Feng 2007) prezentują podejście Bayesa poprzez analizę procesów.

Znakomity opis systemu działającego w praktyce znaleźć można w artykule (Aue et al 2007). Pokazują oni, na przykładzie systemu działającego w Bundes Banku, wiele elementów modeli matematycznych zaimplementowanych w praktyce i otwierają dyskusję nad metodologią pomiaru ryzyka operacyjnego. Inny artykuł dotyczący funkcjonowania systemu pomiaru ryzyka znaleźć można w pracy: (Brown 2005). Z kolei (Shevchenko 2009) prezentuje problemy związane z implementacją systemu od strony teorii matematycznej.

(De Fontnouvelle 2003) jako jeden z nielicznych, opisuje jak w praktyce wygląda dopasowanie różnych modeli rozkładów do danych rzeczywistych, na przykładzie danych, pochodzących z kilku banków, zebranych w ramach projektu LDCE i dochodzi do wniosku, że klasyczne metody oparte na testach statystycznych nie dają wystarczającej podstawy do wyboru optymalnego modelu. Podobną dyskusję znaleźć można w (Moscadelli 2004) oraz (Giacometti 2007). Inne podejście prezentuje (Dutta 2006) omawiając użyteczność rozkładów klasy EVT i g-and-h z punktu widzenia dostępności narzędzi analitycznych w aplikacjach komputerowych.

(Chernobai 2007a) analizuje konieczność wprowadzenia progów minimalnych wartości podczas zbierania i rejestracji strat oraz korekty tych modeli uwzględniające obcięcie danych. Analogiczną dyskusję prezentuje (Mignola 2006), Natomiast (Gabaix 2008) zastanawia się nad wykorzystaniem w tym celu, popularnej w zastosowaniach ekonomicznych, teorii “power law”.

(Frachot 2001) wprowadza bardzo ciekawy model kwantyfikacji wiedzy ekspertów poprzez ocenę parametrów sekwencyjnych. Model ten nie został dotychczas wprowadzony w praktyce, choć ostatnio prezentowany jest w opisach metod analitycznych publikowanych przez Komitet Bazylejski. Inne podejście do kwantyfikacji prezentuje (Garthwaite 2005) analizując zarówno źródła obciążeń i błędów związanych z pozyskiwaniem informacji jak i metody ich obejścia.

(Panjer 2006) to jeden z najpełniejszych wykładów o rodzinach parametrycznych rozkładów używanych w ryzyku operacyjnym. Obejmuje kilkadziesiąt rodzin rozkładów od jedno do cztero-parametrycznych. Kontynuacja i rozszerzenie tej listy znajduje się w (Klugman 2008).

W chwili obecnej bardzo mało jest prac opartych na rzeczywistych danych pozwalających określić czynniki i metody, które mogą być wykorzystane do skalowania danych pochodzących z różnych źródeł. Artykuł (Samad-Khan 2005) to pionierskie wprowadzenie w problematykę wykorzystania

danych zewnętrznych. Dalsze rozwinięcie tych modeli znaleźć można w pracach (Heru 2004) (Heru 2006), i (Baud 2002), (Dahen 2007).

Ważną rolę przy skalowaniu danych odgrywają wskaźniki opisujące środowisko wewnętrzne i zewnętrzne (np. gospodarcze) tzw. KRI. (Fheili 2006) proponuje budowę takich wskaźników, podobnie (Davies 2006).

Przy modelowaniu ryzyka operacyjnego nie można pominąć efektu zabezpieczenia się przed ryzykiem – tzw. mitygacji. Jako główne narzędzie mitygacji wykorzystywane są umowy ubezpieczeniowe (Bazzarello 2006).

Na rynku, szczególnie w Polsce, nie brak gotowych systemów komputerowych wspierających zarządzanie oferowanych przez firmy komercyjne takie jak: (SAS 2007), (RCS 2007), (Oracle 2008), (OPRisk 2008), (Optial 2009). Każde z tych rozwiązań ma swoje silne strony.

3. Przegląd metodologii używanych w zarządzaniu ryzykiem operacyjnym.

3.1. Zarządzanie ryzykiem w instytucjach finansowych – funkcja biznesowa

Fundusze własne, współczynnik wypłacalności, zwrot na kapitale korygowany ryzykiem to pojęcia, które ostatnio bardzo często pojawia się w kontekście zarządzania. Kluczową rolę odgrywa koncepcja wartości zagrożonej (VaR), która pozwoliła zbudować środowisko biznesowe jak i informatyczne niezbędne dla stosowania metod ilościowych. Możliwe stało się wprowadzenie do praktyki skomplikowanych modeli statystycznych poprzez nadanie im finansowej interpretacji.

Podstawowym fundamentem, na którym opiera się metodologia wartości zagrożonej jest kapitał ekonomiczny (*Economic Capital*) – wielkość, która odpowiada wartościowo wszystkim materialnym stratom mogącym wpłynąć na działalność instytucji. Wymóg, aby rezerwy finansowe były równe kapitałowi ekonomicznemu stanowi podstawę wewnętrznych modeli pomiaru ryzyka.

Proces zarządzania to nie tylko modele matematyczne ale i dane. Modele muszą bazować na wielu źródłach informacji takich jak: dostępne dane historyczne ale również prognozy i scenariusze.

Proces zarządzania ryzykiem oraz kontroli ryzyka jest sterowany kilkoma podstawowymi celami, których realizacja umożliwia przedsiębiorstwu jakim jest bank w sposób bezpieczny i zrównoważony wzrost zgodny z założonymi celami finansowymi. Najważniejszymi z nich są:

- zapewnienie wypełnienia wymagań ostrożnościowych, nałożonych przez nadzór, w tym przede wszystkim dotyczących adekwatności kapitałowej,
- ograniczenie całkowitej ekspozycji na ryzyko oraz na poszczególne jego rodzaje do poziomu akceptowanego z punktu widzenia przedsiębiorstwa,
- optymalizacja ekspozycji na ryzyko w stosunku do realizowanego wyniku finansowego.

3.2. Utrzymanie adekwatności kapitałowej

W tym zakresie mieści się zapewnienie zdolności do trwałego wypełniania wymagań nadzorczych opartych o ściśle zdefiniowany zakres metod kalkulacji oraz prezentacji informacji odnoszących się do minimalnych wymagań, co do funduszy własnych, niezbędnych do pokrycia ryzyk generowanych przez działalność przedsiębiorstwa.

System zarządzania ryzykiem musi zapewnić zakres funkcjonalności biznesowej umożliwiający monitorowanie adekwatności kapitałowej:

- pomiar wymogów kapitałowych oraz współczynnika wypłacalności w oparciu o wymagane metody kalkulacji,
- przechowywanie danych wejściowych oraz informacji o elementach rachunku adekwatności kapitałowej odnoszących się do różnych portfeli,

- dystrybucję informacji w formie raportów.

Warunkiem skuteczności w zarządzaniu adekwatnością kapitałową jest codzienne monitorowanie wielkości współczynnika wypłacalności oraz jego poszczególnych elementów składowych.

3.3. Ograniczenie ekspozycji na ryzyko

Ustalenie strategii działania przedsiębiorstwa oraz szczegółowych planów finansowych, jak i obszarów działania towarzyszy określenie maksymalnych pułapów zaangażowania na ryzyko oraz jego poszczególne rodzaje. Odbywa się to w formie ustalania limitów, które mogą mieć charakter:

- ograniczenia wolumenów (np.: limity pozycji)
- ograniczenia ryzyka (np.: limity wartości zagrożonej oraz wrażliwości)
- ograniczenia straty (np.: limity typu "stop-loss")

Limity te muszą mieć strukturę dopasowaną do biznesowego profilu przedsiębiorstwa. Zarządzanie ryzykiem musi umożliwiać przede wszystkim pomiar poszczególnych rodzajów ryzyka, tj. ryzyka rynkowego, ryzyka kredytowego oraz ryzyka operacyjnego, zgodnie z przyjętymi metodami odzwierciedlającymi charakterystykę przedsiębiorstwa oraz praktykę branżową w tym zakresie. Zasadniczą funkcją, poza oczywiście samą kalkulacją parametrów ryzyka, jest dystrybucja informacji o relacji między zamierzonym ryzykiem, a ustalonymi limitami i liczbami kontrolnymi, która pozwoli na prowadzenie właściwego monitoringu ekspozycji na ryzyko oraz przestrzegania ustanowionych ograniczeń.

3.4. Optymalizacja ekspozycji na ryzyko

Podejmowanie ryzyka musi mieć uzasadnienie w oczekiwanym wyniku finansowym mierzonym w adekwatnym do natury inwestycji czasie. W związku z tym istnieje konieczność, z jednej strony symulowania skutków określonych zmian portfeli i towarzyszących tym portfelom czynników ryzyka, z drugiej ustalanie i monitorowanie celów finansowych w kategoriach wiążących wynik z działalności z generowanym przez nią ryzykiem. Funkcje te muszą być obsługiwane przez system zarządzania ryzykiem dając możliwość prezentacji analiz wynikających z miar dochodowości korygowanych ryzykiem oraz symulowania zmienności wyniku, w konsekwencji zmian działalności lub hipotetycznych zmian działalności lub hipotetycznych zmian warunków w otoczeniu banku.

Kluczowym punktem jest jednak pomiar ryzyka, dopiero na nim opierają się wszystkie strategie zarządzania ryzykiem. Zaproponowanie metod pozwalających poprawić miary ryzyka oraz zbadanie czynników wpływających na jego strukturę można uznać za bardzo istotne.

Celem strategicznym banku jest osiągnięcie zakładanej stopy zwrotu na kapitale. Cel ten jest realizowany poprzez prowadzenie działalności obciążonej ryzykiem. Zarządzanie ryzykiem musi zapewnić odpowiednio wczesne rozpoznawanie wszystkich istotnych zmian zarówno wewnątrz banku jak i w środowisku zewnętrznym. Weryfikacja zakresu ryzyk pod kątem istotności odbywa się cyklicznie.

Za istotne uznaje się następujące rodzaje ryzyka:

- ryzyko rynkowe
- ryzyko kredytowe
- ryzyko operacyjne

W dalszej części opisane zostaną procedury pozwalające szacować ryzyko operacyjne.

3.5. Ryzyko operacyjne

Ryzyko operacyjne zawsze było obecne w instytucjach finansowych. W ostatnich latach na skutek szybkiego rozwoju rynku: wprowadzeniu wielu nowych produktów finansowych w tym wysoko kwotowych rozliczeń, deregulacji i globalizacji rynku światowego, wdrożeniu nowych technologii informatycznych przyczyniło się do wzrostu znaczenia ryzyka operacyjnego.

Proces pomiaru i ograniczania ryzyka operacyjnego jest jednym z najważniejszych zadań wchodzących w skład zarządzania ryzykiem.

W styczniu 2001 r. Komitet Bazylejski ds. Nadzoru Bankowego przygotował dokument konsultacyjny „Nowa Bazylejska Umowa Kapitałowa”, w którym zaproponował kilka metod liczenia rezerw w postaci kapitału regulacyjnego związanego z ryzykiem operacyjnym. Dopuszczona została metoda zaawansowana oparta na wewnętrznym systemie pomiaru ryzyka operacyjnego danej instytucji o ile stanowi ona integralną część codziennych procedur zarządzania.

Zgodnie z dokumentem banki mogą obliczać swój wymóg kapitałowy z uwzględnieniem zarówno oczekiwanych, jak i nieoczekiwanych strat. Miara ryzyka operacyjnego musi obejmować potencjalnie duże wypadki skrajne, osiągając normę pewności porównywalną z przedziałem ufności na poziomie 99,9 % przez okres jednego roku.

3.6. Zasady należytego zarządzania dla ryzyka operacyjnego

W wyniku szeroko prowadzonych konsultacji europejski organ nadzorczy Bazylejski Komitet Nadzoru Bankowego (BCBS) - instytucja powstała pod koniec 1974 roku przy Banku Rozrachunków Międzynarodowych (BIS), opublikował zestaw zasad należytego zarządzania ryzykiem operacyjnym. [„Rekomendacja M dotycząca zarządzania ryzykiem operacyjnym w bankach”, KNB W-wa 2004]

Platforma na której powinien się opierać system wspomagający zarządzanie musi zostać zaprojektowana w sposób, który na bieżąco umożliwi wypełnianie ustalonych przez komitet BCBS wymagań w tym zakresie.

Ustalony zbiór zasad i dobrych praktyk w obszarze ryzyka operacyjnego można z powodzeniem stosować nie tylko w przypadku zarządzania ryzykiem w instytucjach sektora bankowego czy ubezpieczeniowego, ale także w pozostałych dziedzinach działalności, w których występuje zjawisko ryzyka operacyjnego, m.in. w przemyśle, lub energetyce.

Zasada 1: Zaangażowanie Zarządu

System do zarządzania ryzykiem operacyjnym powinien umożliwiać identyfikację zdarzeń operacyjnych, ocenę poziomu ryzyka, prowadzenie samooceny, ciągłe monitorowanie poziomu ryzyka oraz umożliwiać realizację procesów kontrolnych dostosowanych do specyfiki instytucji.

Zasada 2: Audyt Wewnętrzny

W ramach prowadzonych cyklicznych walidacji systemu zarządzania ryzykiem operacyjnym, regułą musi być oddzielenia funkcji audytu od funkcji oceny i zarządzania ryzykiem operacyjnym.

Rozwiązanie spełniające te wymagania musi zostać wyposażone w funkcje kontrolne, przeznaczone dla audytorów. Z ich pomocą będą oni mogli niezależnie przeprowadzać ocenę ryzyka, składować i zarządzać jej wynikami. Kompletna ścieżka audytu umożliwia podejmowanie decyzji, zarządzanie nimi oraz wprowadzanie wymaganych działań naprawczych.

Zasada 3: Polityka i procedury

Zarządzanie ryzykiem operacyjnym musi odzwierciedlać specyfikę, strukturę organizacyjną oraz obowiązujące w danej instytucji procedury. Oznacza to, że narzędzie informatyczne wspomagające zarządzanie ryzykiem operacyjnym musi elastycznie i szybko dostosowywać się do wszelkich zachodzących w obrębie organizacji zmian. W ramach projektu systemu funkcję tę najlepiej spełniają bazy danych w postaci workflow pozwalające rejestrować informację o zdarzeniach oraz kontrolować jakość wprowadzanej do systemu informacji. W obrębie workflowu użytkownik ma możliwość definiowania i wprowadzania zmian wywoływanych reorganizacją struktury organizacyjnej banku poprzez przypisywanie uprawnień i odpowiedzialności pracownikom.

Zasada 4: Ocena ryzyka na poziomie produktów, aktywności, procesów, systemów

Platforma powinna posiadać funkcjonalności umożliwiające wypełnienie kluczowych wymagań związanych z oceną ekspertów, definiowaniem ryzyk i wskaźników ryzyka.

Zasada 5: Proces efektywnego monitoringu

System musi być wyposażony w funkcjonalność efektywnego monitorowania, dzięki czemu identyfikacja luk w procedurach lub w procesach jest procesem szybkim. W zależności od zaistniałej sytuacji użytkownik powinien mieć możliwość generowania reguł tworzących monity i przypomnienia, a także eskalowania ich na wyższe poziomy zarządzania z wymaganą przez monitoring częstotliwością.

Zasada 6: Kontrola procedur, polityk i procesów

Ryzyka są oceniane ze względu na ich dotkliwość oraz prawdopodobieństwo zajścia zdarzenia zarówno przed jak i po zastosowaniu odpowiednich działań zaradczych tzw. mitygacji.

Użytkownik systemu musi mieć możliwość śledzenia incydentów operacyjnych i wprowadzania funkcji naprawczych celem wypełnienia wszystkich wymaganych przez procedury zarządzania ryzykiem operacyjnym i zgodności działań związanych z rejestracją zdarzeń operacyjnych aż do momentu ich zamknięcia.

Zasada 7: Plany awaryjne i ciągłości działania

System musi również zapewniać działania w zakresie zarządzania ciągłością oparte na dobrych praktykach wprowadzanych np. przez Institute of Business Continuity. Sprowadza się to do definiowanie planów awaryjnych oraz planów ciągłości działania i zarządzania nimi.

Zasada 8: Współpraca z Nadzorem

Jednolite rozwiązanie powinno umożliwiać poprawny przepływ informacji na potrzeby zarządzania ryzykiem poprzez różne szczeble zarządzania. Dla celów zarządczych informacje powinny być agregowane. Takie podejście zapewnia przejrzystość procesu zarządzania ryzykiem oraz ułatwia komunikację z nadzorcą.

Zasada 9: Niezależność przeglądów

System to jednolite i spójne rozwiązanie, umożliwiające bardziej skuteczne i proste prowadzenie monitoringu ryzyka. Dotyczy to zarówno audytu zewnętrznego jak również procesu automatycznego monitorowania poprzez wykorzystanie systemu alertów związanego z przekraczaniem limitów narzuconych na wskaźniki ryzyka.

Zasada 10: Ujawnienia

Zastosowanie rozwiązania musi zapewnić, że proces zarządzania ryzykiem operacyjnym jest zgodny z wymaganiami nadzorców i dobrymi praktykami, że jest prawidłowo szacowany i monitorowany.

4. Elementy systemu pomiaru ryzyka operacyjnego

Ze względu na mało szczegółowe regulacje w zakresie ryzyka operacyjnego i różnorodność banków żadna sztywna metodologia nie jest odpowiednia we wszystkich przypadkach. W praktyce każdy bank musi stworzyć metodologię, odpowiednią dla jego specyfiki, wdrożyć ją w pełnym obszarze działalności oraz uzyskać zgodę organu nadzorczego na jej stosowanie (BCBS 2001).

4.1. Ogólny opis Systemu wspierającego zarządzanie ryzykiem operacyjnym

System wspomagający zarządzanie ryzykiem składa się z metodologii oraz technologii umożliwiającej jej realizację.

Metodologia zarządzania ryzykiem operacyjnym musi podkreślać jego strategiczne znaczenie i zaangażowanie różnych jednostek organizacyjnych zarówno na poziomie operacyjnym jak i strategicznym. Prawidłowe wewnętrzne procesy związane z ryzykiem operacyjnym charakteryzują się odpowiednim podziałem obowiązków, klarownym zakresem odpowiedzialności i efektywnym raportowaniem i planowaniem kryzysowym.

Następnym krokiem po zdefiniowaniu metodologii zarządzania ryzykiem operacyjnym jest implementacja związanych z nią procedur w postaci rozwiązania informatycznego.


Z procesem tym, łączą się następujące wyzwania:

- Zapewnienie gromadzenia kompletnych, dostępnych danych
- Automatyzacja zbierania danych, agregacja i odpowiednie raportowanie
- Integracja nowych procesów i korekty procesów istniejących w zarządzaniu firmą

4.2. Architektura rozwiązania

Poniższy diagram ilustruje budowę Systemu Wspomagającego Zarządzanie Ryzykiem Operacyjnym, które stanowi rozwiązanie dla systematycznego i spójnego zarządzania ryzykiem operacyjnym w całym przedsiębiorstwie. Podstawowe warstwy systemu to: warstwa „zacztywania” danych (Data Acquisition Layer), warstwa przetwarzania danych i modelowania (Processing and Modeling Layer) oraz warstwa raportowania (Reporting Layer) i dystrybucji informacji (Output Layer).

System składający się z takich elementów zapewnia infrastrukturę dla tworzenia i realizacji zarządzania ryzykiem, szerokiego zakresu kontroli poprawności i zgodności procesów.



Rysunek 3. Schemat Systemu Wspomagającego Zarządzanie Ryzykiem Operacyjnym. Źródło: materiały firmy Optial.

4.3. Opis modułów Systemu Wspierającego Zarządzanie Ryzykiem Operacyjnym.

System pomiaru ryzyka operacyjnego instytucji musi zawierać pewne zasadnicze elementy (moduły). Do elementów tych należą: dane wewnętrzne i zewnętrzne, analiza scenariuszy wariantowych, czynniki odzwierciedlające otoczenie gospodarcze oraz systemy kontroli wewnętrznej oraz procesy przetwarzania danych i dystrybucji informacji (Aue 2007).

Do podstawowych modułów należą:

- Moduł 1: obsługujący zdarzenia i straty operacyjne
- Moduł 2: ocena ryzyka
- Moduł 3: zapewnienia zgodności procedur wewnętrznych z przepisami prawa i dobrych praktyk tzw. Compliance;
- Moduł 4: środki i narzędzia służące do kontroli i audytu
- Moduł 5: zarządzania ciągłości działania
- Moduł 6: Business Intelligence – aplikacja służąca do analiz biznesowych i raportowania

Moduł 1: Zdarzenia i straty operacyjne

Wewnętrzne środki pomiaru ryzyka operacyjnego powinny być oparte na obserwacji historycznej dotyczącej zdarzeń mogących powodować straty obejmującej okres co najmniej pięciu lat. Muszą zawierać informacje na tyle kompleksowe, by objąć wszystkie istotne działania i ekspozycje pochodzące ze wszystkich podsystemów oraz lokalizacji geograficznych. Należy opracować dokładne procedury zbierania danych, w tym określić właściwe progi minimalnych strat do celów gromadzenia wewnętrznych danych na temat strat (Bee 2006). Gromadzone dane powinny zawierać informacje o wielkościach strat oraz identyfikować ich przyczyny. Istotna jest również zdarzeń, które mogą potencjalnie prowadzić do strat, tego typu rejestry mogą być wykorzystane przy budowie i kalibracji modeli analitycznych. Wewnętrzne dane instytucji kredytowej na temat strat muszą zawierać informacje na tyle kompleksowe, by objąć wszystkie istotne działania i ekspozycje. Bank musi wykazać, że dowolne nieuwzględnione działania lub ekspozycje, zarówno indywidualnie, jak i powiązane, nie będą miały istotnego wpływu na całokształt oszacowań ryzyka.

W ramach systemu pomiaru ryzyka operacyjnego bank powinien stosować również odpowiednie dane zewnętrzne, w szczególności wówczas, gdy istnieją podstawy, by przypuszczać, że instytucja jest narażona na potencjalnie poważne, straty. Stanowią one uzupełnienie danych wewnętrznych.

Aby ocenić stopień narażenia na szczególnie niekorzystne zdarzenia, bank powinien również wykorzystywać symulacje **oparte na opiniach ekspertów** w powiązaniu z danymi wewnętrznymi i zewnętrznymi. Z czasem takie oceny muszą być aktualizowane na podstawie porównania z rzeczywiście poniesionymi stratami, co ma na celu zachowanie ich zasadności.

Tworzenie bazy zdarzeń i strat operacyjnych umożliwia zarządowi całościowy ogląd sytuacji dotyczącej ekspozycji na ryzyko operacyjne, transparentnej alokacji odpowiedzialności oraz działań naprawczych.

Zbieranie informacji dotyczących zdarzeń i strat operacyjnych

Proces systematycznego zbierania danych o zdarzeniach i stratach jest jednym z najważniejszych celów, które musi spełnić system służący do zarządzania ryzykiem operacyjnym, ponieważ umożliwia on uzyskanie wielu pomocnych informacji wspierających podejmowanie decyzji biznesowych i minimalizację ryzyka.

W wielu firmach, zbieranie danych dotyczących strat operacyjnych jest scentralizowane w departamencie ryzyka, który integruje informacje uzyskiwane w jednostkach biznesowych i pozwala na tworzenie podsumowań strat zaistniałych w obrębie całej firmy.

Zbieranie danych, u źródła ich powstania, jest kluczowe dla uzyskania natychmiastowej informacji o zdarzeniu i jej walidacji. Umożliwienie ludziom w całej firmie bezpośredniego zapisu informacji na temat zdarzeń oraz strat w prostym formacie jest jedynym sposobem zaangażowania w procesy zarządzania ryzykiem w całej organizacji, a tym samym podniesienie jakości gromadzonych danych. Oczywiście wymaga to wdrożenia skalowalnego systemu IT zapewniającego sprawną interakcję wielu osób.

Od strony technicznej system wprowadzania danych oparty może być na przeglądarce internetowej co pozwala wszystkim autoryzowanym użytkownikom na łatwy dostęp do pojedynczych aplikacji wspierających proces. Zaletą takiego rozwiązania jest umożliwienie bieżącego raportowania sytuacji dotyczącej zdarzeń i strat w wymaganym podziale – np. na typy zdarzeń lub linie biznesowe. Całościowe spojrzenie na listę zdarzeń operacyjnych pozwala na łatwą implementację spójnych standardów ich gromadzenia i przetwarzania.

Zdarzenia i straty mogą być dodawane on-line przez autoryzowanych użytkowników spełniających odpowiednie role, w trybie interakcyjnym bądź ładowane automatycznie z baz danych lub innych systemów produktowych. Rezultatem zdarzeń operacyjnych mogą być zarówno straty jak i zyski, aczkolwiek dla potrzeb zarządzania ryzykiem znaczenie mają tylko te pierwsze. Bank musi wprowadzić zakresy wielkości rejestrowanych strat czyli straty minimalnej czy też ustalenia dotyczące postępowania ze zdarzeniami charakteryzującymi się istotnym wpływem niefinansowym np. na bezpieczeństwo organizacji.

Integralność danych jest jednym z głównych zagadnień w instytucjach finansowych. System musi wspierać spójność gromadzonych danych przy dodawaniu zdarzeń i odpowiednich strat. Bardzo dobrym pomysłem są kontekstowe interfejsy wspierające rejestrację, uzupełnianie wartościami domyślnymi, pomoc podręczną i dynamiczną integrację z zewnętrznymi procesami takimi jak np.: księgowanie. Aczkolwiek trzeba uważać aby forma wprowadzania danych była możliwie prosta.

Każdy bank jest inny co ma swoje odbicie, jeśli spojrzeć na specyfikę danych, jakie powinny być zebrane w bazie strat. Dla uproszczenia, zbierane powinny być tylko istotne informacje potrzebne w procesie zarządzania ryzykiem. Obok standardowego zestawu pól zawierającego opis zdarzenia bądź straty, typy zdarzeń i linie biznesowe bank często potrzebuje dodania własnych, specyficznych informacji. Bardzo istotna jest możliwość konfiguracji systemu bez ingerencji w kod aplikacji, na przykład, jeśli bank ma złożony wielopoziomowy katalog produktów może on zostać dodany do systemu i wówczas każda strata może być połączona z określonym produktem.

Baza strat w systemie powinna posiadać następujące cechy:

- Repozytorium zdarzeń z zakresu ryzyka operacyjnego, zgodności, audytu;
- Zdolność zapisywania i analizy zdarzeń oraz narzędzia pozwalające porządkować informacje, wprowadzanie wartości szacunkowych czy potencjalnych strat, ustalanie priorytetów, analiza

przyczyn. Powyższe czynności wsparte muszą być odpowiednim modelem interakcji użytkowników zawierającym pełen proces z uwzględnieniem wyjątków, eskalacji itp.;

- Możliwość ładowania zdarzeń interaktywnie lub w trybie batchowych kanałów informacyjnych.
- Możliwość ładowania zewnętrznych baz strat równolegle do strat wewnętrznych.
- Export danych do narzędzi statystycznych umożliwiających kwantyfikację ryzyka, jak np.: obliczenie modeli ryzyka.
- Raportowanie w czasie rzeczywistym w formie list, przy użyciu wykresów lub tabel wraz z podsumowaniem i analizą trendów. Umożliwia to dobry wgląd w ekspozycję na ryzyko i wspiera podejmowanie decyzji i analizę źródeł ryzyka.
- System powinien zapewnić wysoki poziom bezpieczeństwa w zakresie gromadzonych danych jak i całej infrastruktury. Jest to realizowane zazwyczaj poprzez system uprawnień dających wgląd do danych tylko dla osób o odpowiednich rolach w odpowiednich obszarach minimalizując szanse na wyciek danych mogących mieć istotny wpływ na działalność banku.
- Możliwość grupowania strat oraz rozdzielania ich na różne centra kosztowe. Istnienie wsparcia dla wielu walut wraz z konwersją na waluty lokalne i bazowe.
- Możliwość dodawania załączników do strat i zdarzeń. Alternatywnie możliwość dodawania odnośników do powiązanych dokumentów.
- Strata powinna być również powiązana z innymi informacjami w systemie, w szczególności z ryzykami, wynikami kontroli lub audytu. Tego typu powiązania najlepiej realizowane są w postaci obiektowej.
- Możliwość dodawanie jednej lub więcej akcji do poszczególnych zdarzeń lub odniesienie wielu zdarzeń do jednej akcji. W szczególności może być dodane połączenie do określonego ryzyka, działań kontrolnych. Każda akcja posiada powiązany z nią program interakcji użytkowników systemu bazujący na zdefiniowanym właścicielu, dzięki czemu status akcji jest skutecznie monitorowany do momentu zamknięcia.

Zdarzenia operacyjne często występują w grupach i kluczowa jest możliwość uwzględnienia ich relacji. System powinien wprowadzić pojęcie 'zdarzenia głównego' umożliwiające grupowanie poszczególnych strat razem w celu wsparcia analiz przyczyn zdarzenia i całościowych efektów.

Loss - Microsoft Internet Explorer

Address: http://localhost:8080/monitor/FinancialImpactMux.do?method=select&handle=10047

SAS OpRisk Monitor

Home Loss Data Risk Management Scenarios KRI Issues and Action Plans Business Structure Financial Data Users and Roles

Losses Recoveries Events Loss Workflow Event Workflow Workflow Summary

Loss

Begin Modification Done Display linked Event

Note: Required fields are marked by * and must be completed.

Summary Information

* Reference Number: 10047 * Confidentiality: Status: Validated

* Title: ATM SHIBUYA PAULA FERN POCASE

* Loss Description: We agreed to pay \$4.5M to settle a lawsuit. The lawsuit had been filed by the family of Paula Fern Pocase, who had been abducted from our ATM branch in Shibuya. She was raped, shot in the head and then set on fire in March 1993. The suit had claimed that we did not provide sufficient security at the ATM location. Payment is made to Justin Allen Maddox and Jeremy Taylor.

Source System: * Impact Type: ☒ Loss ☐ Gain

Loss ID: Operational Component Of Credit Loss? ☒ Yes ☐ No

Contact Name: Contact Details:

Financial Details

Actions	Date of Booking	Financial Status	Ledger Code	Title	Currency	Amount	Amount in EUR
	17/11/2005	Provisioned		Initial loss 0	USD	1,818,363.87	1,550,975.67
	17/11/2005	Provisioned		Initial loss 1	USD	4,049,133.50	3,453,713.32
	17/11/2005	Estimate		Initial loss 2	USD	1,176,584.46	1,003,569.14
	17/11/2005	Settled		Initial loss 3	USD	1,150,876.66	981,641.64

Add Loss Amount...

Operational Risk Point

Business: Retail Banking Group > ATM Services (RBG) > International Service Desk > Pacific Standard Time Service Desk > Japan Money Transfer and Withdrawal Services

Line: > Tokyo ATM Service Desk > Tokyo Shibuya Services Desk

Geography: Americas > North America > United States

Rysunek 4. Przykładowy ekran służący do zbierania informacji o stratach. Źródło: materiały firmy SAS.

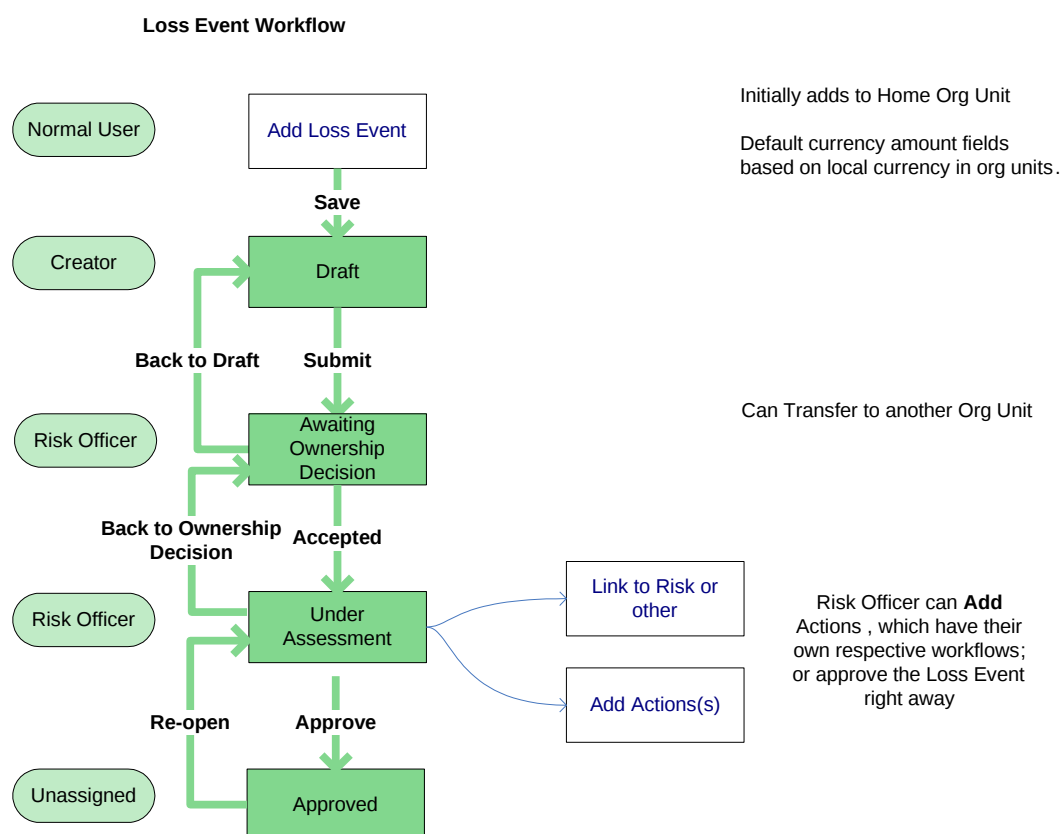
Baza danych wewnętrznych typu *Loss Event Workflow*

Zbieranie danych odbywa się najczęściej w formie *workflow*. Bazy w tej formie najlepiej nadają się do zapewnienia procedury mapowania procesów biznesowych powiązanych ze zdarzeniami czy stratami poprzez ich podział na serie kroków i przepływów. Teksty, grafiki, stopnie i przepływy w procesie są w tym procesie bardzo przydatne. Prosty proces może zostać przedłużony i udoskonalany przy użyciu standardowych funkcji alertów, limitów czasowych, eskalacji, automatycznego zamknięcia pozycji czy ustawienie odczytu na zakończenie.

W zastosowaniach praktycznych często workflow jest obsługiwany dowolną liczbą kroków i przepływów pogrupowanych w tzw. etapy. Postępy każdego etapu pracy są przekazywane w postaci statusu do kolejnej osoby. Ciąg osób i ich role we wprowadzaniu danych mogą być w naturalny sposób definiowane w postaci diagramu przepływu.

Poniżej pokazano przykładowy proces w postaci grafu. Graf przedstawia akcje związane z wprowadzaną informacją. Wprowadzana informacja może być przekazywana dalej do

kolejnej akcji lub cofnięta w celu poprawy lub uzupełnienia. Przedstawiony proces jest wieloetapowy, służy do filtrowania i walidacji wprowadzanej informacji o zdarzeniu. Od momentu wstępnej rejestracji straty w systemie muszą zostać podjęte kolejne działania mające na celu kontrolę jakości informacji.




Rysunek 5. Przykład walidacji dla standardowego zdarzenia operacyjnego/straty. Źródło: materiały firmy Optial.

Zarządzanie akcjami

W Systemie znajduje się pojedyncze repozytorium dla akcji i rekomendacji, dzięki czemu mogą być one zapisane i przetwarzane na czas w zrozumiały i spójny sposób. Wpływa to również na uproszczenia administracji systemu.

Akcje powinny dać się połączyć z dowolnym obiektem w obrębie systemu, w szczególności ze stratami, ryzykami, działaniami kontrolnymi, wskaźnikami środowiska biznesowego KRI lub z rezultatami działań audytowych. Wiele akcji może być połączone z pojedynczym obiektem takim jak zdarzenie czy strata zwana często ryzykiem. Wszystkie połączenia są widoczne w momencie przeglądania informacji na temat danej akcji.

Z każdą akcją związany jest indywidualny proces jej przetwarzania bazujący na jej przyporządkowaniu do kontekstu i wykonawcy. Dzięki temu jej status jest monitorowany od momentu powstania do zakończenia. Osoba, która jest przyporządkowana do więcej niż jednej akcji będzie widziała je wszystkie na swojej liście "Do zrobienia". Dzięki temu użytkownicy systemu uzyskują informacje za co są odpowiedzialni.



Rysunek 6. Przykładowy ekran przedstawiający akcję związaną z monitorowaniem działań kontrolnych. Źródło: materiały firmy Oracle.

Moduł 2: Ocena ryzyka

Aby ocenić stopień narażenia na szczególnie niekorzystne zdarzenia, banki stosują symulacje scenariuszowe oparte na opiniach ekspertów w powiązaniu z danymi wewnętrznymi i zewnętrznymi.

Metoda samooceny (RCSA)

Proces zbierania danych od ekspertów metodą tzw. samooceny jest procesem cyklicznym powtarzanym okresowo. Prostota procesu samooceny jest niezbędna dla osiągnięcia wyników odpowiedniej jakości, jak również zapewnienia, że proces będzie powtarzany w kolejnych rundach. Kluczowe znaczenie ma dobrze przemyślane podejście do najważniejszych elementów takich jak zaplanowanie, przeprowadzenie czy wreszcie analiza, ich wzajemnych relacji i co najważniejsze, jaka jest wizja banku na temat działania całego procesu. To z kolei wymaga systemu zapewniającego dużą elastyczność będącą fundamentalną cechą systemu.

Przeprowadzanie samooceny

W typowym przypadku samoocena przebiega cyklicznie i jest organizowana w formie warsztatów wspartych procedurą ankietowego zebrania danych, z zaangażowaniem wszystkich odpowiedzialnych za dany obszar menedżerów ich wybranych współpracowników - przy wsparciu analityków w zakresie ryzyka. Rezultatem samooceny jest zapisany w systemie wynik opinii ekspertów, w postaci, odpowiedzi na ankiety dotyczące ekspozycji na ryzyko lub sprawozdania z warsztatów wraz z odpowiednią dokumentacją i komentarzami.

Oszacowanie dotkliwości i prawdopodobieństwa strat zarówno przed jak i po uwzględnieniu tzw. kontroli czyli narzędzi pozwalających wdrożyć wyniki wcześniejszych analiz są obecnie częścią standardowego systemu. Banki korzystają z ocen dotkliwości i prawdopodobieństwa, wraz z oceną skuteczności kontroli, aczkolwiek powoduje to szereg trudności analitycznych ponieważ w modelach trzeba uwzględnić zmieniające się warunki biznesowe. Te własności są w pełni konfigurowalne i powinny być dostosowane do specyficznych wymagań. Wskaźniki ekspozycji na ryzyko mogą być wyliczane na podstawie średniego poziomu ryzyka oraz prognoz.

Wszelkie korekty i uzupełnienia wynikające z RCSA dodawane są bezpośrednio do indywidualnych ryzyk, do których się odnoszą. Zarówno RCSA jak i działania kontrolne mają swoje indywidualne procesy workflow, dzięki czemu można łatwo identyfikować odpowiednie obszary wymagające uzupełnień. Ryzyka mogą być łączone z regulacjami oraz wynikami poszczególnych kontroli, działań lub zdarzenia. Konsekwencje z tym związane, kontrole lub procesy wymagają odpowiednich analiz.

W przypadku samooceny, gdy proces warsztatów nie został jeszcze zakończony, odpowiedni alert workflow jest zazwyczaj ustawiany na "time-out" co powoduje uruchomienie, na zasadzie wyjątku, procesu eskalacji lub alarmów.

Biblioteka ryzyk (strat)


Dzięki systematycznemu zrozumieniu i rejestracji czynników ryzyka, które mogłyby zaburzyć osiągnięcie celów biznesowych oraz kontroli zarówno kierunku jak i skuteczności działań, mogą być budowane spójne struktury zarządzania wewnętrznego ryzykiem.

Takie podejście jest zawsze najlepsze. Jednym z rozwiązań, jakie bank może podjąć jest stworzenie biblioteki danych o ryzykach oraz aplikacji pozwalające zarządzać nią zarówno na poziomie globalnym dla całego banku jak i lokalnym dla jednostek biznesowych. Może być ona wykorzystana do obligatoryjnej oceny ryzyka i obowiązkowych kontroli, zgodnie z organizacją metodologii oceny ryzyka. System powinien zawierać narzędzia pozwalające na budowę ustrukturyzowanej biblioteki, w której bank będzie rejestrował swoje własne ryzyko.

Biblioteka składać się powinna z szablonów do rejestracji atrybutów ryzyka, które zostaną wypełnione w trakcie wprowadzania danych i dalszej kolejności posłużą do generowania raportów oceny ryzyka, dla wybranych procesów i jednostek biznesowych. Menedżerowie mogą następnie wykorzystać je do oceny obecnej sytuacji i identyfikacji źródeł strat oraz budowaniu planów działań w celu ich rozwiązania.

Raporty z wyników oceny ryzyka mogą przyjąć różne formy: listy, wykresy, tabele.

Poniższy wykres prezentuje raport typu heat-map. Jest to raport prezentujący ryzyko na skali porządkowej. Na osi poziomej zaznaczone zostały kategorie prawdopodobieństwa pojawienia się straty, a na osi pionowej kategorie skutków (dotkliwości) zdarzenia. Wartość ryzyka przeliczana jest wg reguły $\text{ryzyko} = \text{prawdopodobieństwo} \cdot \text{dotkliwość}$. Za pomocą kolorów zaznaczane są kategorie ryzyka. Za pomocą wykresów tego typu prezentuje się ryzyka zagregowane np. dotyczące danego procesu, produktu lub innego wymiaru.




Rysunek 7. Przykład mapy ryzyka typu „heat-map”. Źródło: materiały firmy Chase Cooper


Kategoryzacja ryzyka i jego rating

Kategoryzacja zdarzeń ma często decydujący wpływ na wartość ryzyka, dlatego też jest niezwykle ważne, aby można było dokładnie określić listę kategorii, która będzie obowiązywała w procesie rejestracji zdarzeń. System powinien zapewnić zarówno standardowe listy zgodne z wymogami nadzoru, jak również możliwość rekonfigurowania listy, zgodnie ze specyfiką procesów banku, co jest szczególnie ważne w przypadku wdrażania systemu, gdy cała metodologia i w szczególności podział zdarzeń dopiero będzie definiowany. Podział zdarzeń zazwyczaj jest wielopoziomowy. Odnosi się to zarówno do procedur rejestracji zdarzeń jak i kontroli. Korzyści z takiego podejścia są duże, jako „punkt startu” można wprowadzić wspólne kategorie ryzyka dla zdarzeń i kontroli, które następnie są rozwijane są na kolejnych poziomach. Dzięki temu bardzo łatwo można stworzyć przekrojowe raporty o zdarzeniach i kontroli, a poszczególne elementy raportu łączyć ze sobą i porównywać.

Poniższy diagram obrazuje koncepcję połączenia zdarzeń, ryzyk i procesów kontroli we wspólnej kategoryzacji. Połączenie może być dokonywane „w locie” podczas robienia raportów bądź analiz – tzw. implicate linking, może też być realizowane na sztywno poprzez odpowiednią indeksację w bazie danych – tzw. explicit linking.



Rysunek 8. Diagram połączeń różnych wymiarów ryzyka – podejście typu IMPLICIT Linking. Źródło materiały firmy Optial.



Rysunek 9. Diagram połączeń różnych wymiarów ryzyka – podejście typu EXPLICIT Linking. Źródło materiały firmy Optial

Istotne jest, aby można łączyć procedury rejestracji i kontroli zdarzeń, np.: poprzez wspólną kategoryzację tzw. „implicitly via categorizations”, albo poprzez tzw. zewnętrzne połączenia “explicitly via user-defined links”. W systemie powinna pojawić się możliwość realizacji i prezentacji obu strategii w procedurach: audytu, polityki wewnętrznej, działaniach naprawczych itp.

Wzorce scenariuszy

Szablony scenariuszy są używane w celu zdefiniowania standardowych scenariuszy ryzyka. Takie scenariusze dotyczą ustalenia prawdopodobieństwa wystąpienia zdarzenia i kosztów związanych z potencjalnym zdarzeniem oraz określenia technik jego ograniczania. Informacje te są następnie wykorzystywane do przeliczania testów napięć (stress tests) i historycznej weryfikacji wyników (backtesting).

Wzorce powinny być tworzone i zapamiętywane w bibliotece wzorców, na różnych poziomach hierarchii organizacyjnej. Wzorce definiowane razem z odpowiednim procesem przepływu zadań (workflow) bazującym na schemacie środowiska prowadzenia warsztatów samooceny.

Szablon ma służyć do przechowania meta-danych scenariusza, takich jak: opis, status, podsumowanie najważniejszych punktów decyzyjnych z warsztatów oraz technik ograniczania. Oceny jakościowe

powinny być oparte na najlepszych i najgorszych scenariuszach w oparciu o szacowane prawdopodobieństwo oraz dotkliwość mierzoną np. w procentowym udziale w ciągu roku. Oceny ilościowe mogą być szacowane w zakresie kwot oczekiwanych strat w przypadkach najlepszych i najgorszych, a także w formie ilości kapitału, który należy zaalokować na dany scenariusz ryzyka.

View Scenario

[Global Insurance](#) > ... > [Personal Products](#)

Application Fraud Scenario

[Go To Parent](#) [Edit](#)

Description

We have tested what would happen if application fraud numbers exceed historical limits, and have found that we are lacking in several areas, namely in controls associated with the Risk. Our current controls are preventative only which leaves us exposed if this scenario were to occur. We have also found that our system is no longer effective at monitoring and approving new applications, instead it is letting too many through that should be red-flagged.

Effective From

24/11/2009

Creator

optialsupport@optial.com

Status

Scenario Approved

Assigned

No Longer Assigned

ID

111647

Created

24/11/2009

Summary Key Decision Points

- New controls must be put in place to resolve fraud after it occurs
- We need to hold more capital on this risk as our current levels will not be appropriate in this scenario
- Enhanced training on what to do when an application is submitted fraudulently
- New systems needed to pick up false applications

Mitigation Technique

Participants

John Smith - Head of Personal Products
Frank Alexander - Finance Director
Tina O'Leary - Head of Operational Risk

Date Submitted for Approval

01/10/2009

Best Case Scenario

Best Case Probability Assessment		Best Case Loss Amount	7,200.00
Best Case Loss Amount-Transaction Currency	GBP	Best Case Annual Probability %	
Best Case Capital Requirement		Best Case Capital Requirement-Transaction Currency	

Worst Case Scenario

Worst Case Impact Assessment	4 Severe	Worst Case Probability Assessment	2 Low
Worst Case Loss Amount	4,200.00	Worst Case Loss Amount-Transaction Currency	GBP
Worst Case Annual Probability %			
Worst Case Capital Requirement		Worst Case Capital Requirement-Transaction Currency	

Worst Case Impact Assessment Justification

This assessment was based on 2000 fraudulent applications being submitted within a 2 month time period and the effect of it on our Business.

Worst Case Probability Assessment Justification

The likelihood of this occurring at this level was based on historical data which showed that we have never received fraudulent applications to this degree.

Links from here

[L4_ Insurance Application Fraud](#)

Incomplete

[remove link](#)

Attached Hierarchy Filtered using Effective Date of Today. [Show all](#)

Application Fraud Scenario - New Controls needed		Outstanding	jim.su.depcomplofficer@gb
Application Fraud Scenario - Increase Capital Number		Outstanding	peter.su.head@gb
Application Fraud Scenario - new system	Resting	Approved	No Longer Assigned
Application Fraud Scenario - purchase new system		Outstanding	andrew.su.normaluser@gb
Scenario Results - 1Oct2009.xlsx			

[Go To Parent](#) [Edit](#)

Rysunek 10. Przykładowy "ekran" scenariusza z odwołaniami do różnych planów działań oraz załącznika w postaci arkusza Excela zawierającego analityczne wyniki . Źródło: materiały firmy Optial

Warto w tym miejscu zwrócić uwagę na problemy związane z oceną atrybutów zdarzeń takich jak:

- Data zdarzenia skutkującego stratą – często zdarzenia są rozciągnięte w czasie
- Metody szacowania wielkości straty – tzw. zdarzenia trudno mierzalne jak np. straty związane z rotacją personelu,
- Straty powiązane ze sobą – tzw. wewnętrzne korelacje , nie powinny być modelowane oddzielnie;
- Pomiar jakościowy i ilościowy – obok szacunków ilościowych rejestrowane są dodatkowe atrybuty zdarzenia, które mogą ale nie muszą mieć wpływ na ryzyko, np. poziom i intensywność działań zapobiegawczych, które można mierzyć przy pomocy tzw. check-list.

Wymienione wyżej przypadki mogą mieć istotny wpływ na pomiar ryzyka natomiast odpowiednie zaadresowanie ich w modelach analitycznych jest bardzo trudne.

Data zdarzenia skutkującego stratą

Oprócz informacji na temat kwot straty brutto instytucje finansowe gromadzą informacje dotyczące daty zdarzenia skutkującego stratą, kwot odzyskanych ze straty brutto, a także informacje opisowe na temat czynników lub przyczyn zdarzenia skutkującego stratą.

Straty operacyjne nie zawsze są identyfikowane w momencie ich zaistnienia. Czasami zostają odkryte kilka dni później, ale zdarza się także, że dopiero po upływie wielu miesięcy. Powstaje zatem pytanie o datę, którą bank powinien przypisać do takiej wewnętrznej straty w bazie danych na temat strat operacyjnych.

Wybór daty zdarzenia skutkującego dużą wewnętrzną stratą może mieć znaczący wpływ na ocenę profilu ryzyka operacyjnego banku w danym momencie.

W praktyce banki przypisują jedną z trzech dat do indywidualnej straty operacyjnej:

- datę wystąpienia straty,
- datę odkrycia straty,
- datę zaksięgowania.

Najczęściej banki wybierają datę wystąpienia lub odkrycia straty. Ma miejsce także praktyka rejestrowania w bazie danych wszystkich trzech dat.

Niewątpliwie wybór daty wystąpienia straty jest uzasadniony dla większości strat operacyjnych zarówno z punktu widzenia zarządzania ryzykiem, jak również obliczania wymogu kapitałowego. Jednakże daty odkrycia straty i zaksięgowania także mają swoje zalety i mogą zostać pożytecznie wykorzystane przez bank. Należy jednak zwrócić uwagę, by nie prowadzić do zniekształceń prawdziwego obrazu profilu ryzyka operacyjnego banku.

Metody szacowania wielkości straty

Dyrektywa nie podaje definicji kwoty straty brutto. Jasne określenie tej wielkości zazwyczaj nie stwarza większych problemów. Jednak czasami pojawiają się trudności. Jako przykład służą duże rozbieżności w wielkości kwoty straty, które mogą powstać przy oszacowaniach szkód związanych z aktywami rzeczowymi w zależności od tego, czy zastosowano wartość księgową, wartość rynkową, czy też koszty wymiany.

Można spierać się, czy kwota straty brutto powinna odzwierciedlać stopień obniżenia wartości ekonomicznej aktywów, w którym to przypadku posłużenie się kosztami wymiany lub wartością rynkową mogłoby być odpowiednie. Jednak często koszty wymiany i wartość rynkowa nie są łatwo dostępne i mogą nie być obiektywnie oszacowane.

Z drugiej strony wartość księgowa, chociaż może odbiegać od wartości rynkowej, jest dostępna i pozostawia mniej miejsca na duże rozbieżności w rezultatach, gdyż opiera się na ustalonych wytycznych księgowych.

Dokonany przez bank wybór metody oddziałuje na wielkość szacowanych strat i wpływa na proces analizy nadzorczej. Użycie wartości księgowej do celów wyliczania kapitału regulacyjnego uczyni oszacowanie kwoty straty prostą czynnością. Należy jednak pamiętać, iż wartość księgowa może być znacznie mniejsza od wartości rynkowej lub kosztów wymiany, a posługiwanie się wyłącznie nią może doprowadzić do niedoszacowania ryzyka. Pomimo subiektywności towarzyszącej obliczeniom kosztów wymiany, uzyskane wielkości mogą zostać użyte w bankowych scenariuszach oraz być przydatne w zarządzaniu ryzykiem.

Straty powiązane ze sobą

Sposób, w jaki banki traktują powiązane ze sobą straty operacyjne, wpływa na wielkość wymogu kapitałowego. W niektórych przypadkach ten wpływ może być znaczny. Należy tutaj przedstawić kilka kwestii budzących wątpliwości.

Bank może doświadczyć strat operacyjnych, które miały miejsce w różnym czasie, ale są związane z tym samym wydarzeniem. Jeżeli wielkości poszczególnych strat są niższe, a ich suma wyższa niż przyjęty przez bank próg minimalnej straty, wówczas nie bez znaczenia jest, w jaki sposób bank z nimi postąpi. Dobrym rozwiązaniem byłoby zsumowanie strat przed umieszczeniem ich w bazie danych o stratach.

Kolejnym zagadnieniem są straty, które dotknęły kilku różnych linii biznesowych, ale powiązane są z tym samym wydarzeniem. W tym przypadku bank ma więcej możliwości postępowania, spośród których można wskazać następujące:

- Jeżeli próg, powyżej którego gromadzone są dane, jest taki sam dla wszystkich linii biznesowych, informacje o stratach są włączane do bazy danych, pod warunkiem, iż zsumowana wartość strat przekracza ustalony próg.
- Jeżeli progi są różne dla poszczególnych linii biznesowych, wówczas do bazy danych włącza się straty, gdy ich zagregowana wartość przekracza najniższy z progów przypisanych do linii biznesowych dotkniętych stratami.

Następnie bank musi zająć się przyporządkowaniem strat. Zazwyczaj dokonuje się tego poprzez przypisanie zsumowanej wartości strat do jednej z linii biznesowych (najczęściej tej, na którą miały one największy wpływ) lub proporcjonalne przyporządkowanie strat do linii biznesowych dotkniętych wydarzeniem skutkującym stratami. Nie jest to jednak zamknięta lista kryteriów.

Na przykład przypisanie strat finalnej tylko na podstawie wartości poszczególnych strat, a z całkowitym pominięciem zsumowanych miar prawdopodobnie doprowadzi do niedoszacowania ryzyka tam, gdzie było ono rezultatem tego samego wydarzenia skutkującego wieloma stratami. Brak uwzględnienia lub niewłaściwe ujęcie tych strat może przyczynić się do wysyłania błędnych sygnałów osobom zarządzającym poszczególnymi liniami biznesowymi oraz osłabić wiarygodność procesu alokacji kapitału

Pomiar jakościowy i ilościowy - analiza ogólna ryzyka

Analiza ryzyka przeprowadzana jest w dwóch wymiarach: dotkliwości czyli ilościowej i jakościowej konsekwencji zdarzenia oraz prawdopodobieństwa zdarzenia mierzonego najczęściej jako częstotliwość wystąpienia w danym przedziale czasu.

Pomiar ryzyka dokonuje się poprzez określenie częstości oraz dotkliwości zdarzenia. Bardzo wygodną metodą jest budowa skali kategoriowej czyli inaczej mówiąc odpowiednich scoringów. Mogą one bazować na wartościach wskaźników KRI oraz wskaźnikach syntetycznych (risk drivers), specyficznych dla danego zdarzenia dzięki czemu do modelu wbudowywany jest mechanizm standaryzacji, transformujemy zdarzenie do postaci standardowej, a następnie liczymy ryzyko.

Najczęściej wykorzystywane są modele typu regresyjnego Generalized Linear Models (GLM) – scoringi. Teoria modeli GLM pozwala wprowadzać zmienne mierzone w skali porządkowej związaną z „natężeniem” oceny dotkliwości i częstości.

Proces budowy modeli startuje od wyboru potencjalnych czynników KRI oraz risk drivers. Selekcje czynników powinny być prowadzone w poszczególnych liniach biznesowej oraz typach zdarzenia. Następnie budowane są procesy pozyskiwania odpowiednich danych ich transformacje i weryfikacja jakości. Na podstawie tych danych kalibrowane są właściwe modele statystyczne.

Proces budowy modelu składa się z następujących etapów:

- wybór potencjalnych czynników – risk driverów, które wejdą do modelu jako zmienne niezależne,
- ocena jakości danych wejściowych – analiza kompletności danych (missing values), analiza zmienności – poszukiwanie obserwacji odległych i influentnych,
- transformacje danych – analiza korelacyjna, dyskretyzacje, tworzenie zmiennych pochodnych, imputacje braków danych,
- techniki wizualizacji danych – budowa jednowymiarowych modeli opisowych pozwalających badać wstępne miary „zależności” pomiędzy danymi czynnikami ryzyka a wystąpieniem defaultu,
- wielowymiarowe modelowanie statystyczne – kalibracja modeli statystycznych klasyfikujących(typu GLM) oraz pomocniczych modeli do dyskretyzacji zmiennych,
- interpretacja i wizualizacja wyników. W celu porównania różnych modeli stosuje się zaawansowane testy statystyczne oraz techniki graficzne pozwalające wybrać optymalny model.

Oddzielne modele analityczne buduje się dla ryzyka inherentnego czyli takiego, które występuje aktualnie, a które można próbować ograniczyć oraz ryzyka residualnego czyli takiego które jest wbudowane w dany proces biznesowy i którego nie da się ograniczyć wewnętrznymi działaniami.

Porównanie ryzyka inherentnego i residualnego prowadzi do odpowiedzi na pytanie dotyczące skuteczności działań zaradczych (kontrolnych).

Analiza ryzyka resztowego.

Ryzyko residualne to rodzaj ryzyka „standardowego” niezależnego od procedur kontrolnych i wpływu środowiska zewnętrznego. Istotnym założeniem przy budowie modeli dla tego ryzyka jest przekonanie, że podobne operacje prowadzą do podobnych skutków zarówno jeżeli chodzi o naturę jak i wielkość ryzyka. Zależy ono od profilu banku.

W celu określenia ryzyka residualnego określa się szczegółowe kryteria (zmienne wskaźnikowe) których spełnienie klasyfikuje ryzyko do określonego przedziału.

Analiza ryzyka inherentnego

Pomiar ryzyka inherentnego uwzględnia procesy kontrolne. Można wyróżnić kategorie kontroli:

- procedury ograniczające ryzyko specyficzne dla danego ryzyka,
- procedury globalne na poziomie całego Banku lub poszczególnych jednostek organizacyjnych.

Wpływ procedur kontrolnych może być modelowany, jako dodatkowe, ilościowe (najczęściej wyrażane w skali porządkowej) risk drivers lub jako korekty zmieniające „ocenę” zdarzenia.

Pomiar wpływu procedury kontrolnej na wartość ryzyka przeprowadzany jest metodą ankietową.

Kluczowe Wskaźniki Ryzyka (KRIs).

Stosowanie przez banki metodologii oceny ryzyka w całej organizacji musi obejmować zasadnicze czynniki otoczenia gospodarczego i kontroli wewnętrznej, które mogą wpłynąć na zmianę profilu ryzyka operacyjnego. Wybór każdego czynnika musi być uzasadniony jego istotnym wpływem na zwiększanie lub zmniejszenie ryzyka. Wrażliwość ocen ryzyka na zmiany czynników ryzyka oraz względna waga różnych czynników powinna opierać się na dobrze uzasadnionych przesłankach. Poza uchwyceniem zmian, możliwym dzięki usprawnieniu kontroli ryzyka, należy w stosowanej metodologii ująć również potencjalny wzrost ryzyka na skutek większej złożoności lub wzrostu skali działalności banku za pomocą ilościowych wskaźników – tzw. kluczowych wskaźników ryzyka KRI (Key Risk Indicators).

Kluczowe wskaźniki ryzyka stanowią podstawę dla system wczesnego ostrzegania w zarządzaniu ryzykiem operacyjnym, pozwalając identyfikować obszary, gdzie zdefiniowane progi ostrożnościowe zostały przekroczone, a tym samym rośnie potencjał niebezpieczeństwa wystąpienia w najbliższym czasie strat.

Kluczowe wskaźniki ryzyka zazwyczaj są automatycznie generowane lub wprowadzone ręcznie. System powinien dostarczyć narzędzia do opracowania i rejestracji wskaźników w obu przypadkach. KRIs można swobodnie definiować bez limitu na liczbę ani rodzaj.

Jeżeli tryb zbierania podstawowych informacji pozwala, proces można zautomatyzować. Na przykład dane o kontroli ryzyka oraz jego ocenie mogą być zbierane w postaci „karty wyników”, którą można skonfigurować do automatycznego generowania wartości KRI w przedziałach czasowych.

Jeżeli podstawowe informacje znajdują się w zewnętrznych systemach operacyjnych, trzeba zdefiniować odpowiednie „linki” do tych systemów za pośrednictwem dedykowanych interfejsów w celu zebrania żądanych informacji. Przykład: liczba transakcji dealera odrzucona z powodu przekroczenia limitów handlowych.

KRI Observation Request ID	Name	Description	Due Date	Period ID	Period Description	Observation Date	Validated?	Submitted?	Create New From	Delete Request
10000	Teller Turnover Rate	Total monthly teller turnover rate	15-Feb-2006	M1FY2006	M1FY2006	31-Jan-2006	No	No		
10001	Teller Turnover Rate	Total monthly teller turnover rate	15-Feb-2006	M1FY2006	M1FY2006	31-Jan-2006	No	No		
10002	Teller Turnover Rate	Total monthly teller turnover rate	15-Feb-2006	M1FY2006	M1FY2006	31-Jan-2006	No	No		
10003	Continuous Vacation Policy Enforcement	Percentage of employees in compliance with the 5 day continuous vacation policy	15-Apr-2006	Q1FY2006	Q1FY2006	31-Mar-2006	No	No		
10004	Continuous Vacation Policy Enforcement	Percentage of employees in compliance with the 5 day continuous vacation policy	15-Apr-2006	Q1FY2006	Q1FY2006	31-Mar-2006	No	No		
10005	Continuous Vacation Policy Enforcement	Percentage of employees in compliance with the 5 day continuous vacation policy	15-Apr-2006	Q1FY2006	Q1FY2006	31-Mar-2006	No	No		
10006	Continuous Vacation Policy Enforcement	Percentage of employees in compliance with the 5 day continuous vacation policy	15-Apr-2006	Q1FY2006	Q1FY2006	31-Mar-2006	No	No		

Rysunek 11. Przykładowy ekran dla KRI: pokazuje listę wskaźników dostępnych w systemie. Źródło: materiały firmy SAS

Występują również sytuacje, w których informacja dostępna jest jedynie w trybie ręcznego wprowadzania, szczególnie gdy nie jest bezpośrednio dostępna w żadnym systemie IT. W tym przypadku, odpowiednio upoważnieni pracownicy powinni wprowadzać wartości KRI bezpośrednio do systemu. Przykład: liczba dni potrzebnych do zamknięcia działalności na koniec miesiąca.

Różne szczegóły dotyczące kluczowych wskaźników ryzyka KRI powinny być włączone do szablonu KRI, ze szczególnym uwzględnieniem szybkości zmian i różnych progów ostrzegawczych.

Wskaźniki KPI (Key Performance Indicators)

Innym rodzajem wskaźników wykorzystywanych w zarządzaniu ryzykiem są tzw. wskaźniki KPI. Są one związane z miarami osiągniętych celów biznesowych korygowanych na ryzyko operacyjne. Oprócz

standardowych wskaźników KPI użytkownik powinien mieć możliwość wyliczania dedykowanych KPI w celu wyznaczenia alokacji, statusów, trendów umożliwiających użytkownikowi biznesowemu porównywanie bieżących wartości w odniesieniu do celów bieżących i określenia jak wskaźniki KPI zachowują się ze względu na upływ czasu. Statusy i trendy mogą być wprowadzane przy użyciu wielorakich stylów graficznych. Dzięki temu, użytkownik może tworzyć raporty mogące sprostać standardom korporacyjnym.

Moduł 3: Zapewnienie Zgodności (Compliance)

Banki muszą identyfikować i monitorować błędne działania, które zazwyczaj wynikają z niewłaściwej polityki banku w świetle przepisów i praw, w sposób uporządkowany. Taki monitoring wprost jest obowiązkiem wchodzącym w zakres działań kontrolnych. Ponadto, metody reakcji na naruszenia stwierdzone podczas kontroli muszą być odpowiednio opisane i monitorowane. Możliwości śledzenia tych działań jest jednym z ważniejszych zadań modułu Zgodności.

Działania kontrolne - ocena jakościowa i ilościowa.

Kluczem do sukcesu w zarządzaniu ryzykiem braku zgodności są odpowiednie raporty ryzyka, kontroli i oceny procesów biznesowych. Aparat statyczny opis zdarzeń jednorazowych nie znajduje tu zastosowania. System powinien posiadać zaimplementowany schemat przepływu zadań w postaci workflowu, który stanowić musi podstawę do dekompozycji każdego procesu biznesowego na serię elementarnych zadań i przepływów. Przez prowadzenie rejestru działań kontrolnych są one śledzone i efektywnie zarządzane.

Wspieranie monitorowania zgodności działań i kontroli oraz badanie ich wiarygodności, może odbywać się w szczególności na podstawie okresowych raportów np.: rekomendowanych przez przepisy SOX odnoszące się do ryzyka i kontroli. Naruszenia są rejestrowane i podlegają analizie zgodności z odpowiednim procesem przepływu zadań, aby wyeliminować możliwość powtórzenia się niekorzystnego zdarzenia oraz zidentyfikować ewentualne inne zagrożenia.

The screenshot displays the OpRisk Evolution software interface. At the top, there's a navigation bar with options like 'Loss Data Collection', 'Action Plans', 'GL Interface', 'Organization Data', 'Scen.', 'Syst Admin', 'Delegation 1 - Delegation ORM', 'Password', 'Preferences', and 'Logout'. Below this, a calendar for May 2006 is visible. The main section is titled 'Loss Data Collection / Events 14221 - IT System'. It includes a search bar and buttons for 'SPECIFIC HISTORY', 'EDIT', 'PRINT', and 'SET AS'. A table with multiple tabs (Main Info, Additional Info, Amount Info, EventAttachment, Loss, Recovery, Provision, A Plan, Tracking Info) is shown. The 'Main Info' tab is active, displaying a table with columns for event details, amounts, and tracking information.

Field	Value	Tracking Info	Timestamp
First Accounts Date	14/02/2006	ORM1 - ORM1	17/02/2006 05:29:11
Gross Loss	120,000.00	ORM1 - ORM1	17/02/2006 05:29:11
Estimated Loss	0.00	LDC - LDC	17/02/2006 05:25:11
Traditional Estimated Loss	0.00	LDC - LDC	17/02/2006 05:25:11
Not Traditional Loss	0.00	LDC - LDC	17/02/2006 05:25:11
Total Loss	120,000.00	ORM1 - ORM1	17/02/2006 05:29:11
Recoveries	0.00	LDC - LDC	17/02/2006 05:25:11
Intragroup Recoveries	0.00	LDC - LDC	17/02/2006 05:25:11
Insurance Recoveries	0.00	LDC - LDC	17/02/2006 05:25:11
Not Insurance Recoveries	0.00	LDC - LDC	17/02/2006 05:25:11
Reserve	0.00	LDC - LDC	17/02/2006 05:25:11

Rysunek 12. Przykładowy "ekran" audytu i kontroli poprawności działań. Źródło: materiały firmy List Group

Działania kontrolne mogą być zarządzane globalnie lub lokalnie i polegają na bieżącemu monitorowaniu obowiązku przestrzegania przepisów. Kontrole powinny być związane z zarejestrowanymi ryzykami, zdarzeniami oraz polityką wewnętrzną.

Moduł 4: Środki i narzędzia służące do audytu

Bank może korzystać z informacji zebranych w ramach wewnętrznego lub zewnętrznego audytu, w celu zapewnienia odpowiedniego zarządzania poprzez pełny przegląd wszystkich ryzyk operacyjnych.

Często, wyniki audytu są dostarczane do menedżerów liniowych w dokumencie, który jest skomplikowany, trudny do zlokalizowania i wdrożenia. Wyniki muszą być dostępne dla wszystkich zainteresowanych np. na stronach intranetowych i aktualizowane na bieżąco.

Audyt

Głównym celem zapisu wyników kontroli, ustaleń i uzgodnionych działań jest zapewnienie przejrzystości i jasności potrzebnych przy rozwiązywaniu problemów stwierdzonych podczas audytu. Do tego celu wykorzystuje się diagramy przepływu pracy tak aby audytorzy i menedżerowie uzyskali wyczerpujące raporty w odpowiednim kontekście.

Ustalenia i uzgodnione działania audytu obejmują:

- Zapamiętywanie najważniejszych informacji dotyczących planu audytu, w tym zapotrzebowania na proponowane badania, jak i kontrole,
- Podział audytorów kontroli i dystrybucji audytów w strukturze organizacyjnej
- Przekazanie wyników kontroli do kierowników liniowych wymienionych w odpowiednich rolach, natychmiast gdy tylko kontrolerzy zakończą formułowania wniosków i działań
- Obsługę wielu wniosków i wielu działań
- Możliwość audytu w obrębie całej struktury organizacyjnej przy użyciu macierzy dystrybucji
- Korzystania z list kontrolnych podczas prowadzenia regularnych kontroli
- Workflow organizujący przetwarzania dat procedur audytów, ustaleń i działań uzgodnionych

Moduł 5: Zarządzanie Ciągłością Działania

Zarządzanie Ciągłością Działania (BCM) jest procesem polegającym na identyfikacji potencjalnych czynników i ich wpływu na stabilność funkcjonowania banku. Podstawowym celem BCM jest zabezpieczenie instytucji poprzez stworzenie elastycznych ram skutecznie chroniących strategiczne obszary działania firmy, a także zabezpieczających dobra niemierzalne (marka, reputacja) przed niekorzystnymi zdarzeniami poczynawszy od niewielkich ze względu na skalę awarii systemów, a skończywszy na zdarzeniach katastroficznych.

Celem BCM jest minimalizacja dotkliwości strat oraz prawdopodobieństwa ich wystąpienia.

Kluczowe elementy realizowane wewnątrz BCM to:

- Analiza biznesowa skutków (BIA)
- Ocena ryzyka
- Kontynuacja Działalności i Strategia


Moduł 6: Business Intelligence – aplikacja służąca do analiz biznesowych i raportowanie



W celu oceny poziomu ryzyka operacyjnego niezbędne jest przedstawienie zbieranych informacji dotyczących bazy strat operacyjnych, ilości rejestrowanych zdarzeń i dotkliwości strat, wyników samooceny itd. w zagregowanej postaci i w najbardziej kompleksowy sposób.

W celu efektywnego i zgodnego z dobrymi praktykami zarządzania ryzykiem operacyjnym, analityk ryzyka jest zobowiązany do raportowania wyższej kadrze zarządzającej informacji określających poziom ryzyka operacyjnego. Oznacza to stałą konieczność prowadzenia zaawansowanych analiz ad hoc w celu szybkiej oceny poziomu ryzyka i przeciwdziałania skutkom zdarzeń.

Funkcjonalność modułu Business Intelligence umożliwia użytkownikowi uzyskanie odpowiedzi na kluczowe pytania w obszarze zarządzania ryzykiem, takie jak: obserwacja trendów liczby oraz dotkliwości zdarzeń operacyjnych w przekrojach geograficznych i biznesowych, wyszukiwanie 5-ciu najistotniejszych dla instytucji ryzyk itd.

System raportowy jest zdefiniowany poprzez strukturę organizacyjną instytucji i jest wspierany przez funkcjonalność aplikacji. Dostęp do wszystkich szczegółów i danych wyświetlanych na raporcie jest realizowany poprzez funkcję drill-down wspierającą szybkie uzyskiwanie na “żądanie” wszystkich niezbędnych informacji. Wykorzystując funkcję drill –down użytkownik ma unikalną możliwość porównywania w czasie wyników ocen ryzyka i prowadzonych audytów zamieszczanych na raportach. Taka unikalna funkcjonalność umożliwia wykrywanie potencjalnych fałszerstw.





Rysunek 13. Przykład raportów graficznych uzyskanych przy użyciu aplikacji BI. Źródło materiały firmy Optial

Aplikacje Business Intelligence umożliwiają menadżerom ryzyka i analitykom:

- Prowadzenie interaktywnych i zaawansowanych analiz biznesowych, monitorowanie i zarządzania ryzykiem operacyjnym z uwzględnieniem wypełniania wymogów zgodności z uwzględnieniem wybranych wymiarów i miar ryzyka.
- Zaawansowane raportowanie, użytkownik może tworzyć raporty, ma możliwość tworzenia odpowiednich tabel i wykresów w celu ukazania informacji we wszystkich możliwych przekrojach.
- Dostęp do możliwych szczegółowych danych poprzez zastosowanie funkcjonalności drill –down.
- Tworzenie raportów typu point-in-time umożliwiających porównywanie danej chwili z danymi historycznymi.
- Połączenie danych zewnętrznych z danymi wewnętrznymi gromadzonymi poprzez aplikację w celu uzyskania kompleksowego spojrzenia na ryzyko i prowadzenie analiz kluczowych wskaźników KPI.

5. Model danych do pomiaru ryzyka operacyjnego w ramach systemu S-OR

5.1. Data Mart systemu S-OR

Przedstawiony poniżej **model danych do pomiaru ryzyka operacyjnego opracowany na potrzeby niniejszej pracy w dalszej części nazywany będzie projektem S-OR**. Głównym celem było stworzenia koncepcji logicznej dla zaawansowanych technik analitycznych. Jego nowatorstwo polega na tym, że pozwala na współpracę z modułami analitycznymi wykorzystującymi zarówno tradycyjne jakościowe analizy jak i bardzo złożone modele statystyczne

Podstawowe wymagania biznesowe banku, które można zrealizować w oparciu o prezentowany model danych to budowa i utrzymanie spójnego repozytorium zdarzeń. W skład prezentowanego modelu wchodzi opis struktury tabel oraz opis procesów.

Strukturą bazodanową dla potrzeb systemu wspomagającego zarządzanie ryzykiem operacyjnym jest tzw. Data Mart. Data Mart funkcjonuje w oparciu o jednolitą metabazę, która pozwala zarejestrować zarówno elementy struktury bazy danych jak i procesy oraz relacje zachodzące między nimi. Na podstawie elementów zarejestrowanych w metabazie tworzone są automatycznie skrypty, każdorazowo, gdy wymagane jest uruchomienie procesu przetwarzania danych. Pozwala to na elastyczne parametryzowanie systemu na poziomie całych procesów.


W proponowanym rozwiązaniu Data Mart stanowi centralny element zintegrowanego systemu. Moduły systemu muszą bazować na informacjach zgromadzonych w strukturach Data Martu. Taki układ pozwala sprawnie zarządzać systemem oraz monitorować przebieg wszystkich przetwarzań.

Przyjęcie takiego rozwiązania prowadzi m.in. do następujących rezultatów:

- ujednolicenia standardu repozytorium przyszłego systemu informacyjnego;
- logicznego powiązania struktur danych w ramach repozytorium w obszary problemowe;
- scentralizowania i zautomatyzowania procesu zarządzania dostępem do danych i zasilania repozytorium systemu;
- wprowadzenia scentralizowanego systemu zarządzania przetwarzaniem danych procesowych, przy zachowaniu możliwości fizycznego rozproszenia aplikacji i przetwarzania na wielu maszynach;
- udostępnienia danych procesowych z różnych systemów.

Data Mart – baza danych

Od strony technologii informatycznych proces wyliczenia wartości ryzyka operacyjnego przebiega zgodnie ze schematem przedstawionym poniżej.



Rysunek 14. Schemat logiczny przetwarzania danych w procesie obliczania ryzyka operacyjnego. Źródło: opracowanie własne na podstawie "The LDA approach for Operational Risk", RMG, 2003


Moduły danych przechowują różne fragmenty informacji niezbędnej do szacowania i monitorowania ryzyka. Odnoszą się one do różnych aspektów zdarzeń. Do przetwarzania w aplikacjach analitycznych dane muszą być odpowiednio przygotowane, gdyż wielkości zbierane różnymi metodami mogą być niespójne. Stąd każdy moduł zawiera dane opisujące nie tylko bezpośrednie atrybuty zdarzeń operacyjnych ale również atrybuty pozwalające na konsolidację całej informacji.

Baza składa się z kilku modułów

- Moduł Danych Wewnętrznych
- Moduł Danych Środowiska Biznesowego KRI
- Moduł Danych Systemu Ubezpieczeń i Monitorowania Działań Zaradczych
- Moduł Danych Samooceny i Scenariuszy
- Moduł Danych Pomocniczych

Poniższe schematy zawierają opis tabel wchodzących w skład poszczególnych modułów. Zostały one zaprojektowane pod kątem wykorzystania ich w systemie pozwalającym budować modele zarówno aktualnego ryzyka jak i prognoz w zadanych horyzontach czasowych.

Schemat poniżej przedstawia opis głównych tabel systemu. Jądrzem modelu jest tabela LOSSES należąca do Modułu Danych Wewnętrznych zawierająca informacje o zdarzeniach, które zostały zgłoszone i zarejestrowane. Pozostałe tabele zawierają kluczowe dane z innych modułów.




Rysunek 15. Podstawowy schemat bazy danych systemu Ryzyka Operacyjnego, Źródło: opracowanie własne

Powiązania pomiędzy poszczególnymi tabelami jak również detaliczny opis ich struktury zostanie przedstawiony w kolejnych sekcjach tego rozdziału. W pierwszej kolejności opisane zostaną połączenia tabel w ramach modułów funkcjonalnych, następnie opisane zostaną struktury tych tabel.

5.2. Moduł Danych Wewnętrznych

Pierwszym modułem prezentowanego modelu danych jest Baza Zdarzeń i Strat. Zawiera historyczne dane o zarejestrowanych zdarzeniach. Można go opisać przy pomocy schematu „gwiazdy”. Podstawą schematu jest tabela faktów „Straty” obudowana licznymi słownikami.




Rysunek 16. Baza Zdarzeń i Strat - Modułu Danych Wewnętrznych. Źródło: opracowanie własne


5.3. Moduł Danych Samooceny i Scenariuszy

Moduł danych samooceny i scenariuszy zawiera dane zebrane od ekspertów na temat ich „opinii” dotyczących przyszłych zdarzeń. Dane scenariuszowe zbierane są w dwóch podstawowych układach:

- Scenariusze parametryczne
- Scenariusze nieparametryczne




Rysunek 17. Baza danych scenariuszy parametrycznych systemu Ryzyka Operacyjnego. Źródło: opracowanie własne



Rysunek 18. Baza danych scenariuszy nieparametrycznych systemu Ryzyka Operacyjnego. Źródło: opracowanie własne

5.4. Moduł Danych Środowiska Biznesowego KRI


Następny moduł niezbędny do prawidłowego działania systemu monitorowania ryzyka to Moduł Danych o Środowisku biznesowym. Pozwala on na budowę modeli skalujących wartości strat ze względu na zmiany środowiska biznesowego Banku, jak również na monitorowanie zewnętrznych czynników mogących być skorelowanymi ze stratami.



Rysunek 19. Baza danych wskaźników KRI systemu Ryzyka Operacyjnego. Źródło: opracowanie własne


5.5. Moduł danych pomocniczych – wymiary i słowniki

Obok danych bezpośrednio służących do budowy i kalibracji modeli niezbędne są informacje pomocnicze w postaci czynników klasyfikujących dane źródłowe w odpowiednie wymiary/hierarchie. Zostały dołączone do opisywanego modelu, gdyż w praktyce system raportowy dostosowywany jest do bardzo różnorodnych potrzeb biznesowych co wiąże się z koniecznością analizy danych w wielu różnych wymiarach. Stąd poszczególne wymiary powinny być opisane swoimi słownikami.



Rysunek 20. Baza danych wymiarów układu systemu Ryzyka Operacyjnego. Źródło: opracowanie własne


Dodatkowym elementem modelu danych jest podsystem słowników. Pełni on funkcje pomocnicze.



Rysunek 21. Podsystem słowników systemu Ryzyka Operacyjnego. Źródło: opracowanie własne


5.6. Moduł Danych Systemu Ubezpieczeń i Monitorowania Działań Zaradczych

System wspomagający zarządzanie ryzykiem operacyjnym musi zapewniać dostęp do instrumentów finansowych pozwalających ograniczyć wpływ zdarzeń i strat na działalność biznesową banku (Baud 2002). Podstawowym instrumentem wykorzystywanym w Banku jest system ubezpieczeń. Poniższy rysunek przedstawia propozycję organizacji danych związanych z ubezpieczeniami.



Rysunek 22. Baza danych podsystemu ubezpieczeń systemu Ryzyka Operacyjnego. Źródło: opracowanie własne

Innym systemem pozwalającym na kontrolę i ograniczenie zarówno liczby jak i wartości strat jest system pozwalający na monitorowanie działań zaradczych.




Rysunek 23. Baza danych podsystemu działań zaradczych systemu Ryzyka Operacyjnego. Źródło: opracowanie własne

5.7. Data Mart - opis procesów systemu S-OR


Kolejnym krokiem opisu systemu jest opis procesów.

Wyznaczanie ryzyka operacyjnego jest kilkustopniowym procesem angażującym wiele modeli analitycznych i informatycznych wykorzystujących wiele źródeł danych. Efektem końcowym procesu są raporty zawierające m.in. wartości wyliczonego kapitału ekonomicznego.



Rysunek 24. Schemat wyliczania ryzyka VaR. Źródło: opracowanie własne

Od strony technologii informatycznych proces wyliczenia wartości ryzyka operacyjnego przebiega zgodnie ze schematem przedstawionym poniżej.



Rysunek 25. Schemat procesu przetwarzania modeli analitycznych. Źródło: opracowanie własne

Wewnętrzny model ryzyka operacyjnego musi opierać się na modelu analitycznym. W ramach takiego modelu zazwyczaj funkcjonują następujące moduły:

- Moduł kontroli środowiska biznesowego (KRI);
- Moduł ocen eksperckich (RCSA);
- Moduł działań kontrolnych (CA)
- Moduł mitygacji ryzyka (BCP);
- Moduł pomiaru ryzyka (VaR) i alokacji kapitału ekonomicznego;

Poszczególne procesy korzystają z przedstawionych wcześniej tabel danych. Ich zadaniem jest przetworzenie danych.

Opis procesów składa się z opisu podstawowych funkcji realizowanych przez dany proces oraz tzw. Przykładów Użycia czyli diagramów opisujących procesy z punktu widzenia użytkowników systemu.

5.8. Procesy KRI.

Procesy KRI to procedury systemu przetwarzające dane o wskaźnikach biznesowych Banku mogących mieć wpływ na pojawienie się i skutki zdarzeń operacyjnych. Wskaźniki KRI używane w Banku warto podzielić na dwie kategorie:

- Wskaźniki Zatwierdzone.
- Wskaźniki Niezatwierdzone


Wskaźniki Zatwierdzone

Powinny być zbierane zgodnie z oficjalną instrukcją, która zabezpiecza możliwość używania ich zarówno w czasie jak i w różnych jednostkach Banku. Dzięki temu procesy KRI mogą zostać włączone do ogólnego systemu raportowania MIS, a nie tylko być wykorzystywane przez analityków ryzyka operacyjnego.

Wskaźniki Niezatwierdzone

Druga klasa wskaźników KRI to tzw. Czynniki Niezatwierdzone. Ich zakres stosowania ograniczony jest do analiz związanych bezpośrednio z zarządzaniem ryzykiem. Dzięki temu, że zmiany ich definicji nie wymagają żmudnego procesu zatwierdzania i publikowania instrukcji mogą być wykorzystywane do budowy modeli analitycznych. Metodologia budowy takich modeli dopuszcza transformowanie czynników używanych w modelach i zazwyczaj nie daje się uzgodnić ze sztywnymi procedurami raportowania obligatoryjnego realizowanymi w ramach systemów MIS.

Schemat modułu KRI



Rysunek 26. Procesy realizowane w ramach modułu KRI. Źródło: opracowanie własne

Wprowadzony podział na Bazę Danych Zatwierdzonych KRI i Niezatwierdzonych KRI służy do lepszego zrozumienia funkcjonalności tych wskaźników wykorzystywanych do monitorowania zdarzeń poprzez kwantyfikację środowiska biznesowego. Są zewnętrzne w stosunku do systemu S-OR i mogą być wykorzystywane w systemie i poza nim.

Zatwierdzone KRI mogą służyć do różnych celów poza systemem S-OR. Niezatwierdzone KRI służą tylko dla celów wewnętrznych S-OR, najczęściej do skalowania dotkliwości i częstości modelowanych zdarzeń w systemie.

Moduł kontroli jakości danych stanowią narzędzia pozwalające monitorować dane wprowadzane do bazy jak i dane już w bazie zapisane.

Zadania realizowane w ramach procesów KRI:

- Rejestracja metryki KRI zatwierdzonej przez odpowiedni departament ryzyka operacyjnego
- Definiowania KRI innych niż oficjalnie zatwierdzonych dla potrzeb np.: R&D
- Zaczynanie danych o KRI,
- Definiowania wartości progowej i krytycznej – może być kilka poziomów tych wartości
- Analizy wartości KRI
- Wspomaganie wyliczania prognoz KRI na zadany horyzont czasowy,
- Generowania raportów monitorujących opartych na KRI dla kierowników departamentu ryzyka i innych departamentów oraz na użytek poziomu zarządczego banku (C-Level)
- Dystrybucja raportów dotyczących KRI
- Kontrola jakości danych KRI.


Przypadki użycia

W procesach KRI bierze udział pięć grup pracowników:

- Administrator Merytoryczny
opiekuje się Bazą Danych Zatwierdzonych KRI, jest odpowiedzialny za jakość danych;
- Akceptant
bierze udział w procedurach kontroli poprawności danych;
- Pracownik przeprowadzający samoocenę
wiele wyników obliczanych w procesie KRI wykorzystywanych jest do procesu przeprowadzania samooceny i budowy scenariusz;
- Analityk
analizy wykonywane w procesach KRI takie jak: wyliczanie progów reakcji w ramach procedur wczesnego ostrzegania, budowa prognoz;

- Przeglądający

Wyniki procesów KRI w postaci raportów używane są do oceny zmian środowiska biznesowego i mogą być wykorzystywane przez inne jednostki biznesowe Banku.



Rysunek 27. Diagram -przypadki użycia- realizowane w ramach modułu KRI. Źródło: opracowanie własne

Zatwierdzone KRI to wskaźniki dopuszczone oficjalnie odpowiednią procedurą w banku. Służą one dla potrzeb systemu S-OR oraz innych systemów banku dlatego muszą być zarządzane indywidualnie. Do każdego Zatwierdzonego KRI musi być zdefiniowany odpowiedni słownik – Metryka, a co za tym idzie muszą być dedykowani odpowiedni pracownicy.

W skład narzędzi używanych na potrzeby tych wskaźników powinny wchodzić:


- metryka,
- narzędzia wspomagające pracę Administratora,

- wzorce podstawowych raportów,

Przypadki użycia

W procesach KRI biorą udział dwie grupy pracowników:

- Administrator Merytoryczny
opiekuje się Bazą Danych Zatwierdzonych KRI, jest odpowiedzialny za jakość danych;
- Akceptant
bierze udział w procedurach kontroli poprawności danych.



Rysunek 28. Diagram -przypadki użycia- realizowane w ramach modułu KRI. Źródło: opracowanie własne

Metryka i workflow KRI

W skład metryki wchodzi informacje, które muszą być przechowywane i które definiują dane KRI. Przykład metryki KRI Zatwierdzonego, w tabeli poniżej przedstawione zostały informacje które powinny być wprowadzone aby można było monitorować „liczbę prób wyłudzeń”.


Tabela. „Liczba prób wyłudzeń na dany miesiąc.”

I. Informacje ogólne:				
Nazwa wskaźnika:		Liczba prób wyłudzeń na dany miesiąc.		
Typ wskaźnika:		Wskaźnik podstawowy		
Jednostka systemowa				
Jednostka monitorująca				
Linia biznesowa:		bankowość detaliczna (Klient Detaliczny, Bankowość Osobista i Prywatna, Bankowość Hipoteczna)		
Obszar ryzyka:		procesy obsługi klientów		
Kategoria ryzyka operacyjnego:		oszustwa zewnętrzne		
II. Szczegółowe informacje o KRI:				
ID wskaźnika KRI:		00		
Jednostka miary wskaźnika KRI:		Liczba prób wyłudzeń na dany miesiąc.		
Wartość progowa KRI:		67		
Wartość krytyczna KRI:		88		
Częstotliwość monitorowania:		Miesięczna		
Okres przejściowy:		Brak		
Data stworzenia KRI:				
Data ostatniej modyfikacji:		-----		
III. Pozostałe informacje o wskaźniku:				
Budowa wskaźnika:		Próby wyłudzeń dotyczą głównie kredytów (ponad 95% przypadków), gwarancji i czeków. W szczególności wśród kredytów dominowały kredyty konsumpcyjne i kredyty mieszkaniowe.		
Związek KRI z ryzykiem operacyjnym		Wzrost wartości KRI może wskazywać na wzrost ryzyka w kategorii oszustw zewnętrznych, które stanowi podstawowe ryzyko identyfikowane w procesach wewnętrznych Banku.		
Zastosowanie wskaźnika:		Monitorowanie nieprawidłowości w procesach obsługi klientów. Prognozowanie liczby prób wyłudzeń. Wykorzystanie w procesie wprowadzania zmian jakościowych do procesów obsługi klientów.		
Data ostatniej weryfikacji KRI:		-----		
Słowa kluczowe:		wyłudzenie, próba		
Źródło danych:				
Sposób wprowadzania danych:		Ręcznie w postaci pliku Excel		
IV. Przekazywanie informacji do jednostki monitorującej KRI:				
Nazwa jednostki przekazującej informacje		Częstotliwość lub termin przekazywania informacji	Zakres przekazywanych informacji	Sposób przekazywania informacji
		Miesięcznie do 16 dnia miesiąca	Zestawienie przygotowane w formie pliku Excel	Elektronicznie

V. Działania ograniczające poziom ryzyka w przypadku przekroczenia wartości progowej:		
	Nazwa jednostki odpowiedzialnej za podjęcie działań	Opis działania ograniczającego poziom ryzyka
		<i>Działania ograniczające, po dokonaniu analizy przyczyn wzrostu liczby prób wyłudzeń, mogą polegać m. in. na:</i> • <i>zmianie przepisów wewnętrznych w zakresie procesów obsługi klientów,</i> • <i>innych działaniach wg uznania departamentów produktowych, które spowodują ograniczenie poziomu ryzyka.</i>
VI. Działania ograniczające poziom ryzyka w przypadku przekroczenia wartości krytycznej:		
	Nazwa jednostki odpowiedzialnej za podjęcie działań	Opis działania ograniczającego poziom ryzyka
		<i>Działania ograniczające, po dokonaniu analizy przyczyn wzrostu liczby prób wyłudzeń, mogą polegać m. in. na:</i> • <i>zmianie przepisów wewnętrznych w zakresie procesów obsługi klientów,</i> • <i>innych działaniach wg uznania departamentów produktowych, które spowodują ograniczenie poziomu ryzyka.</i>

Tabela 1 Tabela. Przykładowa metryka KRI. Źródło opracowanie własne.

Obok metryki, w celu gromadzenia danych o danym KRI musi być zdefiniowany proces wprowadzania danych ilościowych. Najczęściej są to dane subiektywne, stąd ETL dla danych KRI ma postać „work flow”. W praktyce stopień rozbudowania procedury zbierania danych zależy od wielkości banku i możliwości organizacyjnych. Często jeden pracownik realizuje kilka zadań rozpisanych w poniższym diagramie.



Rysunek 29. Zbieranie danych o Zatwierdzonym KRI w postaci workflow. Źródło: opracowanie własne

Moduł Prognoz KRI

Jednym z zadań modułu KRI jest wspomaganie wyliczania prognoz KRI na zadany horyzont czasowy. W tym celu wykorzystuje się mniej lub bardziej zaawansowane modele analityczne prognoz.

Moduł Prognoz obsługiwany przez analityka KRI.




Rysunek 30. Diagram -przypadki użycia- realizowane w ramach modułu KRI. Źródło: opracowanie własne

Analityk powinien być wspomagany przez aplikację statystyczną. Prognoza ma służyć do celów raportowych.

Prognozowanie może być proste takie jak automatycznie budowany model trendu lokalnego lub interaktywne poprzez budowę modeli statystycznych np. zaawansowane modele kointegracyjne.

Poniższy rysunek przedstawia przykładową prognozę wskaźnika KRI (007-A1). Ze względu na występowanie składnika sezonowego dokładność prognozy jest ograniczona, jednakże w prezentowanym przykładzie prognoza miała służyć ilustracji wspomagającej „alert” wysyłany do odpowiedniego odbiorcy.



Rysunek 31. Przykładowa prognoza KRI. Źródło: opracowanie własne

Moduł Wyliczania wartości progowej i krytycznej KRI

Innym zadaniem Modułu KRI jest wyliczanie wartości progowych np. dla celów systemów wczesnego ostrzegania o zmianach w środowisku biznesowym Banku. Zazwyczaj wylicza się dwie wartości:

- Wartość progową
- Wartość krytyczną

Każda wyliczona wartość raportowa jest wg specyficznego schematu i może być wykorzystana do zainicjowania odpowiednich reakcji.

Moduł obsługiwany przez Analityka KRI




Rysunek 32. Diagram -przypadki użycia- realizowane w ramach modułu KRI. Źródło: opracowanie własne

Analityk powinien być wyposażony w aplikację statystyczną.

Bardzo wygodną formą szacowania wartości progowych jest oparcie się na wynikach symulacji stochastycznych. Na podstawie modeli symuluje się możliwe scenariusze metodą Monte Carlo, a następnie na podstawie wiązek symulacji uzyskanych z modelu można określić pożądaną wartość progu oraz wartość krytyczną opierając je na odpowiednich przedziałach ufności i horyzoncie czasowym

Poniżej prezentacja graficzna scenariuszy KRI (007) z 3 letnim horyzontem czasowym. Scenariusze uzyskane zostały na podstawie modelu autoregresji heteroscedastycznej, do prognoz długoterminowych użyty został model niestacjonarny I-GARCH. Wynik symulacji został wykorzystany do obliczenia przedziałów ufności prognoz, aby na ich podstawie określić poziomy ostrzegawcze KRI.



Rysunek 33. Przykładowe scenariusze KRI uzyskane metodą Monte Carlo. Źródło: opracowanie własne


Baza Danych Niezatwierdzonych Wskaźników KRI

Baza Danych Niezatwierdzonych KRI nie musi spełniać rygorystycznych warunków i może być administrowana przez Analityka modułu VaR.

Niezatwierdzone KRI służą wyłącznie na wewnętrzne potrzeby systemu S-OR. Powinny zostać opisane ale nie tak formalnie jak Zatwierdzone KRI.

Niezatwierdzone KRI dobierane są w ten sposób aby były „skorelowane” ze zdarzeniami. Stopień korelacji weryfikowany być powinien przy użyciu np.: modeli regresyjnych. W praktyce okazuje się, że KRI są przydatne do monitorowania częstości występowania strat natomiast wartość strat tzw. dotkliwość jest zazwyczaj słabo powiązana z wartościami KRI. Często wykorzystuje się modele regresyjne w celu powiązania wartości KRI z innymi wskaźnikami używanymi w banku.

W poniższym wykresie indeks satysfakcji klienta (CSI) wykreślono jako funkcję wartości KRI. Wartości KRI, w tym wartości progowe, mogą być tłumaczone za pomocą biznesowego wskaźnika CSI.



Rysunek 34. Analiza regresji jest używana do potwierdzania użyteczności danego wskaźnika KRI. Źródło: opracowanie własne na podstawie A.Mastro,M. Haubenstock „Operational Risk”, The RMA Journal, 2004

Przypadki użycia dla Niezatwierdzonych KRI




Rysunek 35. Diagram -przypadki użycia- realizowane w ramach modułu KRI. Źródło: opracowanie własne

5.9. Procesy RCSA - kwantyfikacja prognoz i opinii eksperckich

Procedury opisane poniżej dotyczą gromadzenia danych RCSA i korzystania z modeli analitycznych. Oddzielnym zagadnieniem jest przeprowadzenie procedury pozyskiwania wiedzy od ekspertów czy to w postaci ankietowej, czy też warsztatów jak również budowa modeli analitycznych. Pozyskiwanie wiedzy odbywa się najczęściej za pomocą kart ankietowych w trakcie spotkań typu warsztatowego i zostanie opisana w następnych rozdziałach.

Schemat modułu RCSA .



Rysunek 36. Procesy realizowane w ramach modułu RCSA. Źródło: opracowanie własne


Zadania realizowane przez procesy RCSA

- Definiowanie standardowych kart RCSA
- Definiowanie niestandardowych definicji RCSA
- Zacztywanie danych RCSA
- Kwantyfikacja wyników RCSA dotyczących wysokości strat (wartość zagrożona wg zadanego percentyla),
- Generowania raportów monitorujących opartych na RCSA dla kierowników departamentu ryzyka i innych departamentów oraz na użytek poziomu zarządczego banku (C-Level)
- Dystrybucja raportów dotyczących RCSA
- Kontrola jakości danych z RCSA.

Przypadki użycia

W procesach RCSA możemy zdefiniować następujące role i zadania uczestników:

- Administrator merytoryczny
Procedura pozyskania wiedzy wymaga swego rodzaju „opiekuna”, jego udział zależy w dużej mierze od przyjętej strategii i została opisana w dalszych rozdziałach
- Pracownik przeprowadzający samoocenę
Jest to ekspert uczestniczący w procesie
- Pracownik raportujący
W wielu przypadkach procesy RCSA są procesami cyklicznymi wymagającymi przygotowania wielu raportów kontrolnych
- Przeglądający
Wyniki procesów RCSA w postaci raportów finalnych używane są do szacowania ryzyka i mogą być wykorzystywane przez inne jednostki biznesowe banku.



Rysunek 37. Diagram -przypadki użycia- realizowane w ramach modułu RCSA. Źródło: opracowanie własne

Najczęściej w bankach stosuje się jedną z dwóch strategii zbierania danych:

1. Metoda ankietowa.
2. Metoda warsztatowa .

W obu przypadkach stosuje się specjalnie przygotowane kwestionariusze, różnica polega na metodzie uzgodnienia wyników – przeprowadza się je metodami statystycznymi na podstawie ankiet lub podczas wspólnego zebrania - warsztatów.

Analiza wyników samooceny


Scenariusze mogą odnosić się do pojedynczych grup zdarzeń, które dopiero na etapie symulacji wyników łączone są w odpowiednie wiązki.

Trzeba zwrócić uwagę, że opisana powyżej metoda nie uwzględnienia „korelacji” pomiędzy scenariuszami z tego względu liczba scenariuszy w ramach jednego procesu zazwyczaj nie przekracza granicy 10-15. Łączna liczba scenariuszy dla różnych linii biznesowych może przekroczyć 100.

W dalszych rozdziałach zostanie opisana szczegółowo procedura kwantyfikacji wyników samooceny.


Pracownik przeprowadzający samoocenę

Narzędzie wspomagające analizę wyników zależy od przyjętej strategii analiz.




Rysunek 38. Schemat wyliczania ryzyka VaR w ramach modułu RCSA. Źródło: opracowanie własne

Analiza wyników samooceny może być prowadzona na poziomie danych. Dane z baz historycznych i dane scenariuszowe wspólnie służą do kalibracji modeli statystycznych. Oczywiście proces łączenia danych musi uwzględnić różną procedury, a więc i różną wiarygodność danych – do tego celu wykorzystuje się różne modele „skalujące”. Proces przetwarzania danych wygląda następująco:



Rysunek 39. Schemat integracji modeli ryzyka VaR. Źródło: opracowanie własne

W innym podejściu proces łączenia przebiega na poziomie modeli, a właściwie na poziomie wyników wartości strat uzyskanych z modeli. Schemat tego podejścia przedstawiony jest poniżej:



Rysunek 40. Schemat integracji modeli ryzyka VaR. Źródło: opracowanie własne


5.10. Procesy pomiaru ryzyka VaR metodą LDA

Głównym celem procedur wspomagających zarządzanie ryzykiem operacyjnym jest wyliczenie wartości tego ryzyka. Oczywiście nie jest to jedyny cel, ale wartość oszacowanego ryzyka jest wykorzystywana do dalszych procedur biznesowych w celu wyliczenia rezerw i innych parametrów taki jak np. współczynnik rentowności itp. Procesy pomiaru ryzyka polegają na przetworzeniu informacji pochodzącej z różnych źródeł danych i policzeniu wartości ryzyka (Cruz 2002).

Przypadki użycia

W procesach VaR możemy zdefiniować role i zadania uczestników:

- Analitik
Przeprowadza analizy opisane w dalszej części rozdziału
- Przeglądający
Pracownik biznesowy odpowiedzialny za walidację merytoryczną wyników



Rysunek 41. Diagram -przypadki użycia- realizowane w ramach modułu VaR. Źródło: opracowanie własne

Analitik uruchamia proces zaczytania danych z do repozytorium VaR, a następnie rejestruje dane w ramach aplikacji VaR.


Użytkownik przeglądający wybiera parametry symulacji z listy tworzonej na etapie modelowania oraz zgodnie z wymaganiami raportowymi i uruchamia proces.

Zadania realizowane w ramach procedur wyliczania wartości zagrożonej.


1. Skalowanie danych wewnętrznych (z wykorzystaniem KRI - aby uwzględnić „zmianę skali biznesu”)
2. Skalowanie danych zewnętrznych
3. Kalibracja parametrów rozkładów częstości metodą ML
4. Kalibracja parametrów rozkładów częstości metodą MM
5. Kalibracja parametrów rozkładów dotkliwości metodą ML
6. Kalibracja parametrów rozkładów dotkliwości metodą MM
7. Wyliczenie miar zależności – korelacje i kopuły
8. Wybór rozkładu dla częstości – testy i walidacja
9. Wybór rozkładu dla dotkliwości – testy i walidacja
10. Generatory liczb losowych - silnik MC
11. Kwantyfikacja RCSA - z aplikacji RCSA
12. Wyliczenie miar ryzyka – metodą MC
13. Mapowanie ubezpieczeń
14. Wartości KRI – z aplikacji KRI
15. Proces łączenia wyników VaR – pochodzących z danych historycznych i RCSA
16. Skalowanie RCSA

Zadania realizowane w tym procesie polegają na budowie, kalibracji i walidacji modeli analitycznych.

Procesy wykonywane w środowisku analitycznym



Rysunek 42. Schemat części I procesów VaR.. Źródło: opracowanie własne




Rysunek 43. Schemat części II procesów VaR.. Źródło: opracowanie własne

Opis zadań realizowanych w ramach procedur wyliczania wartości zagrożonej

Opis poszczególnych zadań został uzupełniony opisem wewnętrznych tabel systemu, które umożliwiają połączenie tych zadań w spójny system.

Tabele wewnętrzne można ułożyć w poniższy schemat – zadania zczytują odpowiednie dane wejściowe z tych tabel i ładują do nich uzyskane wyniki.

W dalszej części rozdziału opisane są detaliczne informacje o strukturze tych tabel.



Rysunek 44. Schemat tabel używanych w procesach VaR. Źródło: opracowanie własne

Skalowanie danych wewnętrznych

Proces ma na celu wypełnienie kolumn: SCALED_LOSS (przeskalowana kwota straty) oraz KRI_VALUE (współczynnik skalujący), a także WEIGHT1 WEIGHT2 WEIGHT3 (waga) w tabeli LOSSES.

Dane są uzupełniane w danej komórce dla danego projektu na podstawie tabeli LOSSES (data LOSS_DATE oraz kwota LOSS_AMOUNT) oraz tabeli z danymi do skalowania (z tabeli KRI).


Jako czynnik skalujący występuje również wartość progu zbierania danych THRESHOLD. Wartość ta wpływa na kalibrację parametrów rozkładów.

Użytkownik powinien wskazać dla poszczególnych komórek projektu zmienne, które mają posłużyć do przeprowadzenia skalowania.

Skalowanie danych wewnętrznych ma na celu „wyrównanie” danych o zdarzeniach w pojedynczej komórce (Linia Biznesowa / Typ zdarzenia).

Skalowanie może odbywać się:

- Na poziomie danych – czynnik skalujący (SCALED_LOSS)
- Na poziomie wartości oczekiwanej – modyfikacja parametrów rozkładu (SCALE_FACTOR)
- Na poziomie wagi obserwacji – uwzględnienie błędów obserwacji (WEIGHT1/2/3)



Rysunek 45. Schemat tabel używanych w procesach skalowania VaR. Źródło: opracowanie własne

Sposób uwzględnienia poszczególnych poziomów skalowania.

Pierwszy poziom skalowania.

Pierwszy poziom obejmuje bezpośrednie danych. Do algorytmów zamiast wartości LOSS trzeba użyć wartość $LOSS \cdot SCALED_LOSS$. Ten typ skalowania ma za zadanie wyrównanie wartości strat ze względu na ich indywidualne cechy staty np. indeks CPI itp.

Algorytmy na tym poziomie muszą być dopasowane do metodologii i będą uzgadniane z klientem. Dopuszczalne metody to: uzależnienie $SCALED_LOSS$ od czynników rynkowych, od czynników wewnętrznych np. dokładność procedur rejestracji danych, czasu.

Drugi poziom skalowania

Drugi poziom obejmuje skalowanie na poziomie modelu dlatego jego uwzględnienie zależy od metody kalibracji modelu. W bieżącej wersji systemu to skalowanie uwzględniane jest tylko w metodzie największej wiarygodności (ML). Polega ono na modyfikacji parametrów rozkładu tak aby uzyskać efekt skalowania wartości średniej. W różnych rozkładach różnie wpływa to na modyfikację pozostałych momentów. Sposób modyfikacji parametrów nie zawsze jest jednoznaczny dlatego trzeba odwołać się do konkretnych algorytmów prezentowanych i dalszych rozdziałach. Skalowanie to obejmuje sytuacje gdy chcemy wprowadzić do danych wpływ czynników opisujących środowisko biznesowe KRI.

Trzeci poziom skalowania

Trzeci poziom obejmuje skalowanie w trakcie kalibracji. Przy metodzie momentów oznacza to wyliczenie empirycznych momentów po przemnożeniu poszczególnych wartości strat przez wagi. W metodzie największej wiarygodności wagi wpływają na składniki logarytmu wiarygodności. Stąd wpływ wag może różnić się od wybranej metody kalibracji. Wag używa się wtedy, gdy zdarzenie lub grupa zdarzeń ma inny poziom dokładności i warto to uwzględnić

Skalowanie danych zewnętrznych

Dane zewnętrzne (zarówno publiczne jak i konsorcjalne) mogą być przechowywane w innych strukturach danych niż dane wewnętrzne.


Skalowanie danych zewnętrznych ma na celu standaryzację danych ze względu na różne mechanizmy rejestracji strat, począwszy od wysokości progu zbierania danych poprzez metodykę szacowania wielkości po możliwość obserwacji danej straty (dotyczy to szczególnie dużych, bardzo rzadkich strat). Dlatego skalowanie ma na celu „zrównanie” ich wartości z wartościami danych wewnętrznych. Problem opisywany jest jako „relative relation methodology”.

Kalibracja rozkładów częstości

W procesie tym następuje dopasowanie parametrów rozkładów metodą największej wiarygodności. Dopasowywanie rozkładu dotkliwości, z listy zadanej tabelą `FREQ_DIST`.

Dopasowanie odbywa się niezależnie dla każdej komórki (`CELL_NUMBER`). Dane wejściowe stanowi tabela `LOSSES` (z uzupełnionymi kolumnami `KRI_FACTOR`, `SCALE_FACTOR` / `SCALED_LOSS_AMOUNT` oraz `WEIGHT1/2/3`).

Tabela `LOSSES` powinna zostać przekształcona do tabeli częstości `FREQ_LOSSES` o zadanej granularności. W tabeli powinny znaleźć się kolumny: identyfikatory komórki takie jak `CELL_ROW`, `DATE`, `KRI_FACTOR`, `FREQUENCY`, średni `THRESHOLD`. Przy liczeniu częstości (kolumna `FREQUENCY`) powinna zostać uwzględniona waga `WEIGHT1/2/3`. `SCALE_FACTOR` / `SCALED_LOSS_AMOUNT` nie powinno być uwzględnione.



Rysunek 46. Schemat tabel używanych w procesach kalibracji modeli częstości VaR. Źródło: opracowanie własne


Kalibracja rozkładów dotkliwości

W procesie następuje dopasowywanie rozkładu dotkliwości, z listy zadanej tabelą SEV_DIST, dopasowanie parametrów rozkładów można wykonać np.: metodą największej wiarygodności.

Dopasowanie odbywa się niezależnie dla każdej komórki (CELL_NUMBER). Dane wejściowe stanowi tabela LOSSES (z uzupełnionymi kolumnami KRI_FACTOR, SCALE_FACTOR / SCALED_LOSS_AMOUNT oraz WEIGHT1/2/3).

Trzeba uwzględnić jeszcze kilka elementów algorytmu.

- Uwzględnić fakt, że występuje próg zbierania danych czyli wartość Threshold, poniżej której dane nie są rejestrowane w danych historycznych. Istnieje kilka metod uwzględnienia progu.
- Uwzględnić fakt, że wartości strat powinny być skalowane wg „miar wielkości biznesu” tzw. KRI. Do skalowania można użyć zarówno wartości aktualnych KRI jak i wartości oczekiwanych KRI. Najczęściej skalowanie odbywa się w ten sposób aby zmodyfikować parametry powiązane z wartością średnią,
- Uwzględnienie wag dla określenia „ważności” obserwacji




Rysunek 47. Schemat tabel używanych w procesach kalibracji modeli dotkliwości VaR. Źródło: opracowanie własne

Wyliczenie miar zależności

Zależności definiowane w tym procesie są zależnościami pomiędzy częstościami i dotkliwością zdarzeń w poszczególnych okresach czasu w komórkach (typu Linia Biznesowa / Typ Ryzyka). Zależności wyznaczane są pomiędzy każdą parą komórek i z nich budowana jest macierz asocjacji.

W procesie wyznaczania miar zależności (np. korelacji i kowariancji) uwzględniane są informacje o stratach (tabela LOSSES) ze wszystkich komórek danego projektu.

Zależności wyznaczane są przy pomocy miar korelacji/asocjacji lub kopuł.




Rysunek 48. Schemat tabel używanych w procesach wyliczania miar zależności VaR. Źródło: opracowanie własne

Wybór rozkładu dla częstości – testy i walidacja

Na podstawie wyznaczonych wartości poszczególnych miar dopasowania (FREQ_MEASURES) oraz wybranej przez użytkownika miary (flagi SEV_DEFAULT_MASURE oraz FREQ_DEFAULT_MEASURE tabeli SELECTED_MEASURES) wybierany jest rozkład częstości dla danej komórki – z tabeli DIST wybierane są parametry rozkładu najlepiej dopasowanego według wybranej miary i zapisywane do tabeli DIST_PARAMETERS. Użytkownik powinien też mieć możliwość modyfikacji parametrów dopasowanego rozkładu (stress-test), a także ręcznego zadania rozkładu.

Wybór rozkładu częstości oraz dotkliwości są ze sobą powiązane poprzez poziom progu THRESHOLD. Powiązanie to zostanie opisane na poziomie algorytmów.


W tym procesie wyświetlane są także raporty z dopasowania, w tym ew. raporty graficzne.



Rysunek 49. Schemat tabel używanych w procesach testowania rozkładów częstości VaR.. Źródło: opracowanie własne

Wybór rozkładu dla dotkliwości – testy i walidacja

Na podstawie wyznaczonych wartości poszczególnych miar dopasowania (SEV_MEASURES) oraz wybranej przez użytkownika miary (flagi SEV_DEFAULT_MEASURE oraz FREQ_DEFAULT_MEASURE tabeli SELECTED_MEASURES) wybierany jest rozkład dotkliwości dla danej komórki – z tabeli DIST wybierane są parametry rozkładu najlepiej dopasowanego według wybranej miary i zapisywane do tabeli DIST_PARAMETERS. Użytkownik powinien też mieć możliwość modyfikacji parametrów dopasowanego rozkładu (stress-test), a także ręcznego zadania rozkładu.




Rysunek 50. Schemat tabel używanych w procesach testowania rozkładów dotkliwości VaR. Źródło: opracowanie własne

Generatory liczb losowych - silnik Monte Carlo

W procesie symulacji Monte Carlo na podstawie przyjętych rozkładów dotkliwości i częstości (DIST_PARAMETERS) wykonywane są symulacje potencjalnych kwot strat dla poszczególnych komórek lub całej macierzy VaR (w zależności od wyboru użytkownika). Uwzględniane są przy tym zależności między komórkami (ROW_COV oraz COLUMN_COV), a także ewentualnie wybrane przez użytkownika scenariusze przedziałowe (NONPARAMETRIC_SCENARIOS – w bazie danych o scenariuszach [do uzupełnienia]).

Użytkownik powinien mieć możliwość wskazania, jaki rodzaj zależności będzie chciał uwzględnić (korelacje/kowariancje, zależności między kolumnami, wierszami lub obydwa rodzaje). Przy wyznaczaniu kwot uwzględniany jest efekt ubezpieczeń właściwych dla danej komórki (tabela INSUARNCES), z uwzględnieniem odpowiednich wag i prawdopodobieństw (kolumny HAIRCUT oraz RECOVERY_PROBABILITY). Na podstawie serii symulacji wyznaczone są kwoty VaR dla zadanych przedziałów (VAR_RANGE), które trafiają do tabeli VAR_VALUES.



Rysunek 51. Schemat tabel używanych w procesach silnika Monte Carlo VaR. Źródło: opracowanie własne

Procesy KRI

W procesie tym wyznaczana jest wartość zagregowana KRI dla poszczególnych dat strat AGGREGATED_KRI. Wartość ta jest następnie dopisywana do tabeli LOSSES. Alternatywnie może się to odbywać bezpośrednio w tym procesie. Wejściem do procesu jest tabela z poszczególnymi obserwacjami KRI wybranymi przez użytkownika (KRI) oraz tabela ze stratami (LOSSES). Na podstawie wskazanej przez użytkownika strategii wyboru KRI wybierane są te czynniki, które najlepiej oddają charakter zmian wartości strat w czasie. Wartości te są następnie agregowane do jednej wartości KRI_VALUE, dla danego dnia straty. Obliczenia te dokonywane są niezależnie w każdej komórce.

Oprócz powyższego proces ten może umożliwiać wskazanie wartości progowych oraz krytycznych, a także innych statystyk dla poszczególnych wskaźników KRI (poprzez odpowiednie prognozy) – KRI_THRESHOLDS.

Proces tworzenia scenariuszy

W tym etapie następuje wprowadzenie własnych rozkładów nieparametrycznych, poprzez zdefiniowanie częstości dla poszczególnych przedziałów dotkliwości strat. Efektem tego etapu jest przygotowana tabela NONPARAMETRIC_SCENARIOS.

Proces łączenia wyników VaR

W procesie tym następuje agregowanie wartości VaR wyznaczonych w poszczególnych algorytmach, w tym wartość VaR z metody LDA – tabela VAR_VALUES.

5.11. Detaliczne informacje o strukturze tabel VaR.

W rozdziale tym opisane są struktury tabel wewnętrznych dla procesów VaR. Nazwy tabel odwołują się do poprzedniego rozdziału.

PROJECTS

Nazwa kolumny	Opis	Format	Uwagi
PROJECT_KEY	Klucz projektu	Numeryczny	Klucz główny
LAYOUT_KEY	Klucz układu	Numeryczny	Klucz pomocniczy
PROJECT_NAME	Nazwa projektu	Znakowy	
PROJECT_DESCRIPTION	Opis projektu	Znakowy	
PROJECT_TYPE	Rodzaj projektu	Znakowy	Np. testowy użytkownika, oficjalny (produkcyjny) itp.
AVAILABLE	Dostępność dla innych użytkowników		Np. Dostępny, tylko do odczytu, niedostępny
LOCKED	Projekt zablokowany	Binarny	Projektu zablokowanego nie można edytować
OWNER	Właściciel	Znakowy	
RESPONSIBLE_PERSON	Osoba odpowiedzialna	Znakowy	
CALCULATION_DATE	Data przetwarzania	DD_MM_YYYY	
Status projektu		Numeryczny	
Inne (...)?			

Tabela 2. Metryka systemu. Źródło opracowanie własne

KRI

Nazwa kolumny	Opis	Format	Uwagi
PROJECT_KEY	Klucz projektu – identyfikuje projekt	Numeryczny	Klucz tabeli PROJECTS
CELL_NUMBER	Numer komórki- wyznacza zakres KRI	Numeryczny	
KRI_DATE	Data wprowadzenia KRI	DD MM YYYY	
KRI_METRIC_KEY	Metryka KRI	Numeryczny	Klucz tabeli KRI_METRICS
KRI_VALUE	Wartość KRI	Numeryczny	

Tabela 3. Szereg czasowy wartości KRI, przypisanych do poszczególnych komórek projektu. Źródło opracowanie własne

KRI_LEVELS

Nazwa kolumny	Opis	Format	Uwagi
KRI_METRIC_KEY	Metryka KRI	Numeryczny	Klucz tabeli KRI_METRICS
DATE	Data raportu	DD_MM_YYYY	
THRESHOLD_VALUE1	Wartość progowa KRI	Numeryczny	Zgodnie z metryką
THRESHOLD_VALUE2	Wartość krytyczna KRI	Numeryczny	Zgodnie z metryką
STATISTIC_1	Wartość 1 statystyki pomocniczej	Numeryczny	
STATISTIC_2	Wartość 2 statystyki pomocniczej	Numeryczny	

Tabela 4. Wyznaczone statystyki szeregów KRI – w tym wartości progowe oraz krytyczne. Źródło opracowanie własne

LOSSES

Nazwa kolumny	Opis	Format	Uwagi
LOSS_KEY	Identyfikator straty	Numeryczny	
CELL_NUMBER1	Numer komórki	Numeryczny	
Weight1	Waga przypisywana zdarzeniu dla danej komórki	Numeryczny	
CELL_NUMBER2	Numer komórki	Numeryczny	Komórki leżące w kilku komórkach?
Weight2	Waga przypisywana zdarzeniu dla danej komórki	Numeryczny	
CELL_NUMBER3	Numer komórki	Numeryczny	
Weight3	Waga przypisywana zdarzeniu dla danej komórki	Numeryczny	
LOSS_DATE	Data straty	DD_MM_YYYY	
KRI_VALUE	Zagregowany współczynnik	Numeryczny	Współczynnik skalujący ze

	KRI		względem na KRI
LOSS_AMOUNT	Kwota straty netto	Numeryczny	
SCALED_LOSS_AMOUNT	Kwota straty po przeskalowaniu	Numeryczny	
THRESHOLD	Próg zbierania danych	Numeryczny	
SCALED_FACTOR	Współczynnik skalujący	Numeryczny	
WEIGHT0	Waga – drugi czynnik skalujący dla zdarzenia	Numeryczny	

Tabela 5. Informacje o stratach w ramach danego projektu, z podziałem na komórki. Źródło opracowanie własne

ROW_COV

Nazwa kolumny	Opis	Format	Uwagi
PROJECT_KEY	Klucz projektu	Numeryczny	Klucz tabeli PROJECTS
CELL_ROW1	Numer 1 wiersza	Numeryczny	
SEV_COV_VALUE	Kowariancja dla dotkliwości	Numeryczny	
FREQ_COV_VALUE	Kowariancja dla częstości	Numeryczny	

Tabela 6. Wyznaczone wartości kowariancji dla poszczególnych wierszy danego projektu. Źródło opracowanie własne

COLUMN_COV

Nazwa kolumny	Opis	Format	Uwagi
PROJECT_KEY	Klucz projektu	Numeryczny	Klucz tabeli PROJECTS
CELL_COLUMN1	Numer 1 kolumny	Znakowy	
SEV_COV_VALUE	Kowariancja dla dotkliwości	Numeryczny	
FREQ_COV_VALUE	Kowariancja dla częstości	Numeryczny	

Tabela 7. Wyznaczone wartości kowariancji dla poszczególnych kolumn danego projektu. Źródło opracowanie własne

DIST

Nazwa kolumny	Opis	Format	Uwagi
PROJECT_KEY	Klucz projektu	Numeryczny	Klucz tabeli PROJECTS
CELL_NUMBER	Numer komórki	Numeryczny	
DATE	Data przetwarzania	DD_MM_YYYY	
SEV_DIST	Id rozkładu dotkliwości	Numeryczny	Zgodne z merytką rozkładów
SEV_PARM1	Wartość 1 parametru rozkładu dotkliwości	Numeryczny	
SEV_PARM1_Low	Dolna wartość przedziału ufności 1 parametru r. dotkliwości	Numeryczny	
SEV_PARM1_Up	Górna wartość przedziału ufności 1 parametru r. dotkliwości	Numeryczny	
SEV_PARM2	Wartość 2 parametru rozkładu dotkliwości	Numeryczny	
SEV_PARM2_Low	Dolna wartość przedziału ufności 2 parametru r. dotkliwości	Numeryczny	
SEV_PARM2_Up	Górna wartość przedziału ufności 2 parametru r. dotkliwości	Numeryczny	
SEV_PARM3	Wartość 3 parametru rozkładu dotkliwości	Numeryczny	
SEV_PARM3_Low	Dolna wartość przedziału ufności 3 parametru r. dotkliwości	Numeryczny	
SEV_PARM3_Up	Górna wartość przedziału ufności 3 parametru r. dotkliwości	Numeryczny	
SEV_PARM4	Wartość 4 parametru rozkładu dotkliwości	Numeryczny	
SEV_PARM4_Low	Dolna wartość przedziału ufności 4 parametru r. dotkliwości	Numeryczny	
SEV_PARM4_Up	Górna wartość przedziału ufności 4 parametru r. dotkliwości	Numeryczny	
FREQ_DIST	Id rozkładu częstości	Numeryczny	Zgodne z merytką rozkładów
FREQ_PARM1	Wartość 1 parametru rozkładu częstości	Numeryczny	
FREQ_PARM1_Low	Dolna wartość przedziału ufności 1 parametru r. częstości	Numeryczny	
FREQ_PARM1_Up	Górna wartość przedziału ufności 1 parametru r. częstości	Numeryczny	

	parametru r. częstości		
FREQ_PARM2	Wartość 2 parametru rozkładu częstości	Numeryczny	
FREQ_PARM2_Low	Dolna wartość przedziału ufności 2 parametru r. częstości	Numeryczny	
FREQ_PARM2_Up	Górna wartość przedziału ufności 2 parametru r. częstości	Numeryczny	
FREQ_PARM3	Wartość 3 parametru rozkładu częstości	Numeryczny	
FREQ_PARM3_Low	Dolna wartość przedziału ufności 3 parametru r. częstości	Numeryczny	
FREQ_PARM3_Up	Górna wartość przedziału ufności 3 parametru r. częstości	Numeryczny	
FREQ_PARM4	Wartość 4 parametru rozkładu częstości	Numeryczny	
FREQ_PARM4_Low	Dolna wartość przedziału ufności 4 parametru r. częstości	Numeryczny	
FREQ_PARM4_Up	Górna wartość przedziału ufności 4 parametru r. częstości	Numeryczny	

Tabela 8. Wyznaczone parametry dopasowanych rozkładów, wraz z ich przedziałami ufności – dla każdej komórki niezależnie. Źródło opracowanie własne

SEV_DIST

Nazwa kolumny	Opis	Format	Uwagi
PROJECT_KEY	Klucz projektu	Numeryczny	Klucz tabeli PROJECTS
Date	Data przetwarzania	DD_MM_YYYY	
CELL_NUMBER	Numer komórki	Numeryczny	
SEV_DIST	Identyfikator rozkładu dotkliwości	Numeryczny	

Tabela 9. Wybrane rozkłady dotkliwości – do dopasowania w danej komórce. Źródło opracowanie własne

FREQ_DIST

Nazwa kolumny	Opis	Format	Uwagi
PROJECT_KEY	Klucz projektu	Numeryczny	Klucz tabeli PROJECTS
Date	Data przetwarzania	DD_MM_YYYY	
CELL_NUMBER	Numer komórki	Numeryczny	
FREQ_DIST	Identyfikator rozkładu częstości	Numeryczny	

Tabela 10. Wybrane rozkłady częstości – do dopasowania w danej komórce. Źródło opracowanie własne

SEV_MEASURES

Nazwa kolumny	Opis	Format	Uwagi
PROJECT_KEY	Klucz projektu	Numeryczny	Klucz tabeli PROJECTS
Date	Data przetwarzania	DD_MM_YYYY	
CELL_NUMBER	Numer komórki	Numeryczny	
SEV_DIST	Identyfikator rozkładu dotkliwości	Numeryczny	
SEV_MEASURE_NAME	Identyfikator miary dopasowania dotkliwości	Numeryczny	
SEV_MEASURE_VALUE	Wartość miary dopasowania	Numeryczny	

Tabela 11. Wartości miar jakości dopasowania poszczególnych rozkładów dotkliwości do rzeczywistych rozkładów strat w danej komórce. Źródło opracowanie własne

FREQ_MEASURES

Nazwa kolumny	Opis	Format	Uwagi
PROJECT_KEY	Klucz projektu	Numeryczny	Klucz tabeli PROJECTS
Date	Data przetwarzania	DD_MM_YYYY	
CELL_NUMBER	Numer komórki	Numeryczny	

FREQ_DIST	Identyfikator rozkładu częstości	Numeryczny	
FREQ_MEASURE_NAME	Id miary dopasowania częstości	Numeryczny	
FREQ_MEASURE_VALUE	Wartość miary dopasowania częstości	Numeryczny	

Tabela 12. Wartości miar jakości dopasowania poszczególnych rozkładów częstości do rzeczywistych rozkładów strat w danej komórce. Źródło opracowanie własne

SELECTED_MEASURES

Nazwa kolumny	Opis	Format	Uwagi
PROJECT_KEY	Klucz projektu	Numeryczny	Klucz tabeli PROJECTS
SEV_MEASURE_NAME	Nazwa miary dopasowania r. dotkliwości	Znakowy	
FREQ_MEASURE_NAME	Nazwa miary dopasowania r. częstości	Znakowy	
SEV_DEFAULT_MEASURE	Domyślna miara dotkliwości (flaga)	Binarny	
FREQ_DEFAULT_MEASURE	Domyślna miara częstości (flaga)	Binarny	

Tabela 13. Wybrane miary jakości dopasowania – osobno dla rozkładu dotkliwości i częstości (dla całego projektu). Źródło opracowanie własne

6. Opis procesu: zarządzanie ryzykiem i samoocena RCSA

Niniejszy rozdział stanowi wprowadzenie do opisu i oceny metod pozyskiwania danych od ekspertów. Dla potrzeb ryzyka operacyjnego wiedza ekspertów musi być przedstawiona w postaci ilościowej. Potrzebna jest więc metodologia kwantyfikacji ich wiedzy.

6.1. Wprowadzenie

Proces pozyskiwania wiedzy w ramach zarządzania ryzykiem operacyjnym nosi nazwę samooceny a dokładniej Zarządzanie Ryzykiem i Samoocena (Risk Control and Self Assessment – RCSA). Celem samooceny jest transformacja wiedzy eksperckiej dotyczącej zdarzeń operacyjnych do postaci umożliwiającej wykorzystanie jej w ramach modeli analitycznych. W praktyce oznacza to podzielenie zdarzeń na odpowiednie klasy i oszacowanie częstości i dotkliwości danej klasy zdarzeń w postaci np. rozkładów prawdopodobieństwa.

Zarządzanie ryzykiem i samoocenę należy rozumieć jako element procesu zarządzania ryzykiem operacyjnym, pozwalający identyfikować, kontrolować i ograniczać ryzyko operacyjne w banku w oparciu o dane uzyskane od ekspertów. Proces ten musi być włączony integralnie do całego systemu zarządzania ryzykiem operacyjnym, toteż często wykorzystuje składniki takie jak wewnętrzna baza zdarzeń operacyjnych i strat, zewnętrzna baza strat, kluczowe wskaźniki ryzyka (KRI). Zarządzanie ryzykiem i samoocena wykonywane są przez osoby odpowiedzialne za zarządzanie ryzykiem operacyjnym w banku, przy wsparciu odpowiednich narzędzi.

Narzędzia wspierające zarządzanie ryzykiem i samooceną zależą od metodyki zarządzania ryzykiem operacyjnym przyjętej w banku.

Proces samooceny organizowany może być w różny sposób. Najczęściej wygląda on w ten sposób, że budowane są hipotetyczne scenariusze możliwych zdarzeń, które następnie kwantyfikuje się czyli określa prawdopodobieństwa wartości i częstości strat w ramach tych scenariusz. Oddzielnym problemem jest określenie wiarygodności scenariusza w postaci np. wagi.

Jako wynik scenariusza rozumiemy wyniki jakościowe i ilościowe. Wyniki jakościowe to pewne wskazówki co do ważności zdarzeń, natomiast wyniki ilościowe to dane do modeli analitycznych pozwalające na precyzyjną analizę zdarzeń.

Wymagania biznesowe i metodyka

Wymagania biznesowe banku dotyczące oceny ryzyka operacyjnego zawarte są w różnych procedurach czasami formalnie wprowadzonych ale również często będących w fazie zwyczajowych procedur:

- Zasady zarządzania ryzykiem operacyjnym
- Metodyka identyfikacji ryzyka operacyjnego dla produktów i procesów Banku
- Metodyka identyfikacji i oceny ryzyka operacyjnego dla aplikacji informatycznych Banku

- Metodyka identyfikacji i oceny ryzyka braku zgodności dla procesów wewnętrznych Banku


Kluczowe procedury, praktyki i najważniejsze wymagania wynikające z powyższych metodyk dotyczą:

- Ograniczania do możliwego minimum poziomu ryzyka operacyjnego w wyniku stosowania działań profilaktycznych redukujących ryzyko operacyjne oraz jego skutki poprzez prowadzenie cyklicznego procesu samooceny uwzględniającego ocenę: procesów, systemów, produktów oraz elementów struktury organizacyjnej Banku.
- Monitorowania dopuszczalnego poziomu ryzyka operacyjnego przeprowadzane w ramach procesów kontroli wyznaczonych limitów na ryzyko operacyjne, audytu wewnętrznego oraz kontroli funkcjonalnej.
- Wyliczania wymogu kapitałowego na ryzyko operacyjne zgodnie z wymaganiami nadzorczymi opartego na pomiarze ryzyka.
- Stosowania metody samooceny jako uzupełnienia metod ilościowych w celu identyfikacji prawdopodobieństwa zajścia zdarzeń ryzyka operacyjnego oraz określenia związanych z nim wysokości strat finansowych.
- Włączenia procesu samooceny ryzyka operacyjnego w procesy zarządzania ryzykiem i uwzględnianie uzyskiwanych wyników w monitorowaniu, kontroli i zarządzaniu profilem ryzyka operacyjnego Banku co oznacza:
 - przypisywanie ryzyk do procesów, określanie ich inherentności - czyli do jakiego stopnia są one nierozdzielnie związane z działalnością biznesową, istotności oraz przypisanie do nich odpowiednich procesów kontroli oraz właścicieli;
 - identyfikację i ocenę ryzyka operacyjnego poprzez tworzenie i zarządzanie kwestionariuszami ankietowymi tworzonymi na użytek zbierania danych, przypisywanie wag dla poszczególnych pytań kwestionariusza oraz definiowanie i wyliczanie na ich podstawie poziomu ryzyka operacyjnego, a także dokumentowanie przeprowadzonych ocen wraz z historią przetwarzania poszczególnych kwestionariuszy;
 - ocenę ilościową i jakościową ryzyka operacyjnego w kwestionariuszach szacowaną na podstawie różnych kryteriów - w tym, w szczególności ocenę prawdopodobieństwa wystąpienia zdarzenia oraz jego konsekwencje finansowe dla ryzyka absolutnego (inherentnego) i pozostałego (rezydualnego), gdzie ryzyko inherentne oznacza ryzyko związane daną działalnością w warunkach normalnych natomiast ryzyko rezydualne to ryzyko, którego mimo wdrożenia procedur kontrolnych nie można wyeliminować;
 - stworzenie mapy ryzyka operacyjnego w postaci np. diagramów określających stopień zagrożenia oraz raportów prezentujących profil ryzyka operacyjnego w podziale na linie biznesowe, procesy, zdarzenia,
 - opis oraz ocenę istniejących mechanizmów kontrolnych dla każdego zidentyfikowanego ryzyka ze szczególnym uwzględnieniem adekwatności i skuteczności kontroli.

Metodyka zarządzania ryzykiem operacyjnym wyznacza zasady stosowane celem identyfikacji, kontroli, pomiaru i ograniczania ryzyka operacyjnego. Kluczowe elementy metodyki powinny obejmować sposoby zbierania informacji o zdarzeniach i stratach wewnętrznych, identyfikacji ryzyk, samooceny, zarządzania ryzykiem oraz działania zapobiegawcze, modele szacowania ryzyka (np. metodą VaR) wraz z zastosowaniem danych zewnętrznych.

Na potrzeby niniejszej pracy opisywana metodyka ograniczona została do metod analitycznych regulujących procesu pomiaru ryzyka, a wartość biznesowa ryzyka zredukowana została w tym przypadku do informacji o wartości kapitału ekonomicznego.

Ogólne zależności i przepływy informacji między różnymi modułami systemu przedstawiono na schemacie poniżej.



Rysunek 52. Diagram przepływu informacji pomiędzy poszczególnymi procesami zarządzania ryzykiem operacyjnym.
Źródło: opracowanie własne

Zadaniem niniejszej pracy nie jest określenie kompletnej metodyki zarządzania ryzykiem operacyjnym, ale opisanie podstawowych zasad zarządzania ryzykiem, które mogą mieć wpływ na działanie systemu. Z tego punktu widzenia najistotniejsze elementy to: identyfikacja ryzyk i samoocena. Zostaną one opisane w dalszej części pracy.

Podstawą do kwantyfikacji wiedzy ekspertów - samooceny jest metoda budowy i analizy scenariuszy zwana sbAMA (scenario-based Advanced Measurement Approach) (Chernobai 2007b).

6.2. Proces samooceny

Proces samooceny, jest jedną z metod gromadzenia danych niezbędnych do wyliczenia ryzyka z tytułu działalności operacyjnej w metodzie podejścia zaawansowanego Advanced Measurement

Approach (AMA). Metoda ta stosowana jest najczęściej w sytuacji braku lub ograniczonego wolumenu danych o wewnętrznych stratach banku (Fumika 2004).

Podejście to, korzystające z wiedzy ekspertów dziedzinowych, pozwala na systemowe oszacowanie poziomu ryzyka w całej organizacji i dla wszystkich przewidywalnych kategorii ryzyka, a przez to zastosowanie zaawansowanych modeli wyznaczania kapitału regulacyjnego.

Obszary podlegające samoocenie np. kategorie ryzyk, jednostki organizacyjne, procesy identyfikowane są okresowo, a następnie uzupełniane w trybie zarządzania zmianami, wynikającymi np. z wprowadzenia nowych produktów, zmian struktury organizacyjnej itp. Identyfikacja obszarów podlegających ocenie wykonywana jest przez ekspertów dysponujących informacjami: o kompletności wewnętrznej bazy zdarzeń operacyjnych w banku, zewnętrznych bazach strat oraz innymi informacjami o możliwych zdarzeniach operacyjnych.

Samoocena, w wybranych obszarach, wykonywana jest z zastosowaniem kwestionariuszy mających na celu oszacowanie poziomu ryzyka w danym „punkcie” działalności banku. Każdy „punkt” organizacji, w którym mogą zmaterializować się ryzyka operacyjne jest oceniany z wykorzystaniem szeregu miar poziomu ryzyka operacyjnego takich jak:


- Dotkliwość straty;
- Częstość zdarzenia/prawdopodobieństwo zdarzenia;
- Minimalna wartość straty;
- Maksymalna wartość straty.

Samoocena przygotowywana i koordynowana powinna być przez departament ryzyka operacyjnego i zgodności. Trzeba tutaj podkreślić obszar tzw. zgodności, który oznacza ryzyko operacyjne związane z różnicą pomiędzy wewnętrznymi procedurami i rozporządzeniami banku, a prawnym środowiskiem zewnętrznym. Przygotowanie samooceny obejmuje: zidentyfikowanie obszarów podlegających ocenie, przygotowanie miar ryzyka w postaci pytań oraz kwestionariuszy. W realizacji powyższego zadania wykorzystywane są ryzyka, procedury kontrolne i dokumentacje przyczyn zidentyfikowane we wcześniejszych procesach identyfikacji ryzyk.

Przygotowane kwestionariusze dystrybuowane są do ekspertów oraz oficerów ryzyka operacyjnego w każdym z ocenianych obszarów, przy czym ta sama kategoria zdarzeń operacyjnych, przyczyn lub procedur kontrolnych, występująca w różnych „punktach” organizacji może być oceniana przez wielu ekspertów. Oceny dokonane przez ekspertów podlegają walidacji przez pracowników zarządzających danym obszarem działalności banku (np. kierowników lub dyrektorów). Zaakceptowane przez nich oceny przekazywane są do departamentu ryzyka operacyjnego i zgodności, gdzie poddawane są ponownej walidacji pod kątem wpływu na pomiar ryzyka poprzez szacowanie np. kapitału ekonomicznego banku.

Poniższy diagram pokazuje sposób przetwarzania danych uzyskanych w wyniku samooceny. Informacje pozyskane z samooceny, w połączeniu z danymi o stratach przeliczane są z

zastosowaniem modeli statystycznych a następnie wykorzystywane do wyznaczenia wartości kapitału na pokrycie ryzyka operacyjnego (Teplý 2006).



Rysunek 53. Schemat przetwarzania danych o stratach z wykorzystaniem bazy Global SAS. Źródło opracowanie własne.

1. Ważną informacją, która musi być brana pod uwagę jest próg strat minimalnych, które są rejestrowane w bazie, trzeba wziąć pod uwagę, że próg ten może zmieniać się w czasie
2. Scenariusze uzyskiwane przez ekspertów mają charakter prognoz i najczęściej wyrażane są w postaci rozkładów prawdopodobieństwa np. histogramów;
3. Połączenie danych z bazy danych o stratach (dane historyczne) oraz danych od ekspertów (dane prognostyczne) wymaga stosowania modeli skalujących, na tym etapie dodawane są również dane zewnętrzne np. SAS-GlobalData;
4. Wyliczenie ryzyka w postaci percentyla straty zagregowanej w jednostce czasu np. jednego roku tzw. kapitału ekonomicznego

W trakcie samooceny dokonywana jest również ocena przyczyn występowania ryzyk oraz stosowanych środków zapobiegawczych mających na celu zmniejszenie prawdopodobieństwa materializacji ryzyk.

Efektem samooceny może być również dokumentacja problemów, które wymagają przygotowania planów działań mających na celu ograniczenie poziomu ryzyka operacyjnego. Pozwala to na aktywne nim zarządzanie.

W proces samooceny zaangażowane być mogą wszystkie jednostki organizacyjne banku.

Często, jest korzystne, przed przystąpieniem do procedury RCSA rozważenie restrukturyzacji procesów w celu oceny ryzyka całego procesu lub linii biznesowej (zgodnie z zasadami ustalonymi np. przez dyrektywę SOx 404), lub przeprowadzić proces RCSA według określonej lokalizacji, np. standardowy proces może często działać w różnych lokalizacjach organizacyjnych jak i geograficznych, jak np. procedury księgowe w ramach oddziałów.

Ryzyka

Ryzyko operacyjne powinno być rozpatrywane zarówno jako ryzyko faktyczne ale również ryzyko potencjalne, które nieodłącznie towarzyszy działalności operacyjnej. Chcąc oszacować ryzyko trzeba brać pod uwagę środowisko wewnętrzne, jak i czynniki wynikające z uwarunkowań zewnętrznych, w tym np. trendów w branży. Osobnym zaganiem jest przewidywanie nowo pojawiających się zagrożeń.

W niektórych przypadkach wygodnie jest określić kategorie wysokiego poziomu dla ryzyka operacyjnego w celu identyfikacji konkretnych ryzyk związanych z daną działalnością, podczas gdy w innych lepiej jest używać podejścia procesowego w celu ułatwienia ich procesu identyfikacji. Do celów samooceny trzeba rozważyć różne sposoby charakteryzowania i opisu zagrożeń. Na przykład, badanie czynników w postaci związków przyczynowo skutkowych może zapewnić znacznie skuteczniejszy wgląd w profil ryzyka i często jest przydatne w wyborze najbardziej efektywnych strategii zarządzania ryzykiem.

Czynniki ryzyka, często, ze swej natury są nakierowane na przyszłość, a tym samym przewidywanie przyszłych problemów. Istnieje wiele zagrożeń, które mogą obejmować takie kategorie jak: ludzi, zadowolenie klientów, wolumeny transakcji, poziom zmian organizacyjnych. Te kategorie czynników ryzyka można interpretować bardzo szeroko. Na przykład czynnik: "Ludzie" może łączyć się z poziomem zatrudnienia, umiejętnościami pracowników, ale także efektywnością pracy.

Procesy kontrolne

Pojęcie kontroli w RCSA odgrywa kluczową rolę. Definicja kontroli obejmuje te elementy zarządzania, które zapewniają ochronę przed konkretnym ryzykiem. Kontrola najczęściej polega na:

- Zapobieganiu - tę kategorię kontroli można też nazwać "przed wydarzeniem";
- Wykrywaniu - ta kategoria może być również nazywany "po wydarzeniem".

Przykłady typowych kontroli zarówno finansowych jak i niefinansowych sektora bankowego obejmują: nadzór kierowniczy, podział obowiązków, kluczowe wskaźniki wydajności, procedury, szkolenie itp.

Funkcje procedur RCSA mogą zawierać wyraźne zalecenia weryfikacji skuteczności kontroli, np. dokładne zdefiniowanie roli właściciela procesu kontroli odpowiedzialnego za badania, czy kontrole działają w praktyce. Właściciel kontroli sprawdza procedury kontrolne i tworzy sprawozdania. Gdy oceny kontroli wykazują jej nieskuteczność, wówczas należy rozważyć czy są odpowiednio zaprojektowane zarówno na poziomie podstawowych instancji jak i całego procesu kontrolnego, czy też problemem jest sama realizacja kontroli.

Ocena ryzyka

Banki wykorzystują metodologie oceny ryzyka inherentnego (ocena ryzyka bez stosowania mechanizmów kontrolnych) lub ryzyka rezydualnego (po zastosowaniu mechanizmów kontrolnych), jako ważny element procesu RCSA. Oczekiwanym rezultatem jest to, że ryzyka rezydualne będą

niższe niż inherentne. Różnica powinna zależeć od zakresu i skuteczności kontroli wewnętrznej (Ebnöther 2003).

Identyfikacja profilu ryzyka inherentnego może być subiektywna i zależeć od wielu czynników, a sam pomiar obciążony jest obciążeniami wynikającymi z technik pomiarowych. Jest trudny do oszacowania, choć umożliwia bankowi ocenę korzyści z procesów kontroli poprzez porównanie z poziomem ryzyka w sytuacji braku kontroli.

Często banki używają metody RCSA, aby ocenić poziom bieżącego ryzyka operacyjnego, przyjmując, że poziom kontroli nie podlega pomiarowi. Przy takim podejściu uznaje się, że zrozumienie profilu ryzyka nie jest niezbędne w celu wprowadzania udoskonaleń do istniejącego systemu zarządzania ryzykiem.

Zmiany w systemie kontroli mogą być sterowane poprzez analizę rzeczywistych wydarzeń i kontrole mogą być poddane ponownej ocenie w świetle aktualnych strat.

Dane scenariuszowe

Na potrzeby samooceny scenariusze są generowane tak, aby mogły uzupełniać dane zbierane z innych źródeł takich jak:

- dane wewnętrzne o stratach banku (baza danych o stratach wewnętrznych - ILD),
- doświadczenia zebrane z innych podobnych instytucji (dane zewnętrzne o straty - ELD),
- oraz innych dostępne informacje w środowisku biznesowym (KRI).

Należy zauważyć, że nie ma szczegółowych regulacji prawnych dotyczących warunków, które i jakie informacje powinny być wykorzystane do generowania scenariusza. Zgodnie z wymogami regulacyjnymi (Basel), wszystkie trzy elementy danych (ILD, ELD i KRI), wraz z danymi scenariuszowymi, muszą być wykorzystane bezpośrednio lub pośrednio w modelu kapitału, w celów obliczania kapitału ekonomicznego (Chernobai 2007a) (Teplý 2006).

Spośród wyżej wymienionych źródeł danych, zewnętrzne dane o stratach są wykorzystywane głównie, jako wytyczne do generacji scenariuszy. Dane zewnętrzne dotyczą przede wszystkim wielkość kwoty strat, są zbierane w podziale na typy zdarzeń. Bardzo pomocny jest przy tym fakt, że dyrektywy nadzorcze, regulujące raportowanie obowiązkowe, wymienia typy zdarzeń.

W pierwszej kolejności warto zwrócić uwagę, że scenariusze buduje się dla zdarzeń które powstają w „podobnych” warunkach, mają homogeniczne źródło. W tym celu zdarzenia dzieli się na klasy. Najbardziej rozpowszechnionym podziałem jest podział na:

- Typy zdarzeń
- Linie biznesowe

Dopuszczalny jest również podział na procesy. W niniejszej pracy ograniczymy się do podstawowego podziału na typy i linie .

Podział na kategorie dokonywany jest hierarchicznie poprzez wprowadzenie 2-3 poziomów. Ściśle zdefiniowany przez nadzorcę (Basel) jest pierwszy poziom. W tabeli poniżej wypisane zostały definicje kategorii bazylejskich:

Kategoria zdarzenia	Definicja
Oszustwa wewnętrzne	– Straty spowodowane działaniem polegającym na celowej defraudacji, sprzeniewierzeniu majątku, obejściu regulacji, przepisów prawa lub przepisów wewnętrznych przedsiębiorstwa, wyłączając straty wynikające z różnorodnością lub dyskryminacją pracowników, które dotyczą co najmniej jednej osoby wewnętrznej
Oszustwa zewnętrzne	– Straty spowodowane celowym działaniem polegającym na defraudacji, sprzeniewierzeniu majątku lub naruszeniu przepisów prawa przez stronę trzecią
Zasady dotyczące zatrudnienia oraz bezpieczeństwo w miejscu pracy	– Straty powstałe na skutek działań niezgodnych z przepisami lub porozumieniami dotyczącymi zatrudnienia, bezpieczeństwa i zdrowia w pracy, wypłaty odszkodowań z tytułu uszkodzenia ciała lub straty wynikające ze zróżnicowania i dyskryminacji pracowników
Klienci, produkty i praktyki operacyjne	– Straty wynikające z niewywiązania się z obowiązków zawodowych względem konkretnych klientów, będące skutkiem działań nieumyślnych lub zaniedbania (w tym wymagań fiducjarnych i stosownego zachowania) lub też związane z charakterem bądź konstrukcją produktu
Szkody związane z aktywami rzeczowymi	– Straty powstałe na skutek straty lub szkody w aktywach rzeczowych na skutek klęski żywiołowej lub innych wydarzeń
Zakłócenie działalności gospodarczej i awaria systemów	– Straty powstałe na skutek zakłócenia działalności gospodarczej lub awarii systemów
Wykonanie transakcji, dostawa i zarządzanie procesami operacyjnymi	– Straty powstałe na skutek nieprawidłowego rozliczenia transakcji lub wadliwego zarządzania procesami operacyjnymi oraz wynikłe ze stosunków z kontrahentami i sprzedawcami

Tabela 14. Kategorie zdarzeń wymienione w dyrektywach nadzorczych (kategorie bazylejskie). Źródło „Dziennik Urzędowy Unii Europejskiej C 227”, 2005

Co prawda banki mają swobodę w kształtowaniu swoich modeli wewnętrznych, ale ponieważ muszą raportować do nadzoru w kategoriach bazylejskich bardzo często stosują typy bazylejskie, jako swoją podstawę. Pozwala to na pewną standaryzację przy korzystaniu z baz zewnętrznych

Obok kategorii zdarzeń do definiowania scenariuszy trzeba wprowadzić dodatkowy wymiar – linia biznesowa. Oba wymiary definiują tzw. „komórki”. „Komórka” jest definiowana ze względu na typ strat w ramach linii biznesowych. Scenariusze są generowane w poszczególnych „komórkach”. Choć podział może obejmować również cały bank lub pod-linie biznesowe. „Komórka” zostaje ustalona na podstawie decyzji dotyczącej zarządzania ryzykiem przed wygenerowaniem danych scenariuszowych.

Podział na linie biznesowe dokonywany jest hierarchicznie poprzez wprowadzenie 2-3 poziomów. Ściśle zdefiniowany przez nadzorcę (Basel) jest pierwszy poziom. W tabeli poniżej wypisane zostały definicje bazylejskich linii biznesowych:

Linia Biznesowa	Produkty i usługi
Bankowość inwestycyjna	– Gwarantowanie emisji instrumentów finansowych lub sub-emisja instrumentów finansowych z gwarancją przejęcia emisji – Usługi związane z gwarantowaniem emisji – Doradztwo inwestycyjne – Doradztwo dla podmiotów gospodarczych dotyczące struktury kapitałowej, strategii branżowej i zagadnienia pokrewnych oraz doradztwo i usługi w zakresie fuzji i przejęć podmiotów gospodarczych – Badania inwestycyjne i analiza finansowa oraz inne formy ogólnych zaleceń w sprawie transakcji związanych z instrumentami finansowymi
Działalność dealerska	– Zawieranie transakcji na własny rachunek – Usługi brokerskie na rynku pieniężnym – Przyjmowanie oraz przekazywanie zleceń w związku z jednym lub większą ilością instrumentów finansowych – Wykonywanie zleceń w imieniu klienta – Sub-emisja instrumentów finansowych bez gwarancji przejęcia emisji – Operacje w alternatywnym systemie obrotu
Detaliczna działalność brokerska	– Przyjmowanie oraz przekazywanie zleceń w związku z jednym lub większą ilością instrumentów finansowych – Wykonywanie zleceń w imieniu klienta – Sub-emisja instrumentów finansowych bez gwarancji przejęcia emisji
Bankowość komercyjna	– Przyjmowanie depozytów i innych środków zwrotnych – Udzielanie kredytu – Leasing finansowy – Gwarancje i zobowiązania
Bankowość detaliczna	– Przyjmowanie wkładów pieniężnych i innych środków powierzonych pod tytułem zwrotnym – Udzielanie kredytów – Leasing finansowy – Udzielanie gwarancji i zobowiązań pozabilansowych
Płatności i rozliczenia	– Usługi związane z transferem środków pieniężnych – Emitowanie instrumentów płatniczych i administrowanie nimi
Usługi agencyjne	– Przechowywanie instrumentów finansowych i administrowanie nimi na rachunkach klientów, w tym usługi powiernicze i pokrewne, takie jak zarządzanie gotówką /zabezpieczeniem
Zarządzanie aktywami	– Zarządzanie portfelem – Zarządzanie podmiotami zbiorowego lokowania w handlowe papiery wartościowe (UCITS) – Inne formy zarządzania aktywami

Tabela 15. Linie biznesowe wymienione w dyrektywach nadzorczych (linie bazylejskie). Źródło: „Dziennik Urzędowy Unii Europejskiej C 227”, 2005

Dla niektórych „komórek”, może nie być wystarczającej liczby wewnętrznych strat niezbędnych do stosowania metod statystycznych, wówczas, można uzupełniać dane z baz danych zewnętrznych. Ze względu na stosunkowo małą dostępność zewnętrznych danych, na podstawie testów statystycznych

trzeba upewnić się, że nasze podejście do tych „komórek”, gdzie są podejrzenia co do liczby danych historycznych nie zapewnia możliwości budowy stabilnego modelu.

Metoda opisana w następnej części nie zależy explicite od źródeł danych, które zostały wykorzystane do modelu, jednakże niestabilność modelu podstawowego powoduje duże obciążenie wpływu scenariusza na wynik pomiaru ryzyka.

W poniższej tabeli zestawiono wyniki analiz w 89 bankach europejskich. Podział zdarzeń na „komórki” dokonano na podstawie definicji typów zdarzeń i linii bazylejskich. W niektórych komórkach liczba zdarzeń jest duża, co oznacza, że w tym obszarze biznesowym można budować modele na podstawie danych historycznych. Ewentualne uzupełnienie tych danych scenariuszami może mieć na celu korektę wyników pod kątem „rzadkich” zdarzeń. Dla niektórych „komórek” liczba zdarzeń jest bardzo mała, co oznacza, że w tych obszarach biznesowych musimy wykorzystać scenariusze do kalibracji całego zakresu dotkliwości zdarzeń.

Liczba zdarzeń prowadzących do strat w podziale na Linie Biznesowe i Typy Zdarzeń

Wszystkie banki i wszystkie straty (w raporcie uczestniczyło 89 banków)

	Oszustwa wewnętrzne	Oszustwa zewnętrzne	Zasady dotyczące zatrudnienia oraz bezpieczeństwa w miejscu pracy	Klienci, produkty i praktyki operacyjne	Szkody związane z aktywami rzeczowymi	Zakłócenie działalności gospodarczej i awaria systemów	Wykonanie transakcji, dostawa i zarządzanie procesami operacyjnymi	Razem
Bankowość inwestycyjna	17	20	73	73	16	8	214	421
	0.04%	0.04%	0.15%	0.15%	0.03%	0.02%	0.45%	0.89%
Detaliczna działalność brokerska	47	95	101	108	33	137	4603	5124
	0.10%	0.20%	0.21%	0.23%	0.07%	0.29%	9.74%	10.86%
Bankowość detaliczna	1268	17107	2063	2125	520	163	5289	28535
	2.68%	36.19%	4.36%	4.50%	1.10%	0.34%	11.19%	61.10%
Bankowość komercyjna	84	1799	82	308	50	47	1012	3382
	0.18%	3.81%	0.17%	0.65%	0.11%	0.10%	2.14%	7.22%
Płatności i rozliczenia	23	322	54	25	9	82	1334	1849
	0.05%	0.68%	0.11%	0.05%	0.02%	0.17%	2.82%	3.92%
Usługi agencyjne	3	15	19	27	8	32	1381	1485
	0.01%	0.03%	0.04%	0.06%	0.02%	0.07%	2.92%	3.15%
Zarządzanie aktywami	28	44	39	131	6	16	837	1101
	0.06%	0.09%	0.08%	0.28%	0.01%	0.03%	1.77%	2.35%
Działalność dealerska	59	20	794	539	7	50	1773	3242
	0.07%	1.31%	1.70%	0.11%	0.03%	0.01%	0.29%	3.59%
Razem	1529	19422	3225	3336	649	535	16443	45139
	3.31%	42.39%	8.52%	7.17%	1.40%	1.14%	35.07%	100.00%

Tabela 16. Liczebność zdarzeń w podziale na typy zdarzeń bazylejskich i linie biznesowe bazylejskie. Źródło (BCBS 2003)

Często wymagane jest połączenie tych „komórek”, w których nie było wystarczającej liczby strat, aby można było stworzyć inny podział na „komórki”. Możemy nazwać takie komórki „inne”. W praktyce łączy się komórki ze względu na linie biznesowe.

Przykładowy podział na „komórki” oraz schemat ich łączenia :

Podział na kategorie bazylejskie	Podział na kategorie wewnętrzne	Linie biznesowe						
		LB1	LB2	LB3	LB4	LB5	LB6	"Linia wsparcia"
Oszustwa wewnętrzne	Oszustwa	1	2	3	4	5	6	7
Oszustwa zewnętrzne								
Szkody związane z aktywami rzeczowymi	Infrastruktura	8						
Zakłócenie działalności gospodarczej i awaria systemów								
Klienci, produkty i praktyki operacyjne	Klienci, produkty i praktyki operacyjne	9	10	11	12	13	14	15
Wykonanie transakcji, dostawa i zarządzanie procesami operacyjnymi	Wykonanie transakcji, dostawa i zarządzanie procesami operacyjnymi	16	17	18	19	20	21	22
Zasady dotyczące zatrudnienia oraz bezpieczeństwo w miejscu pracy	Zasady dotyczące zatrudnienia oraz bezpieczeństwo w miejscu pracy	23						

Tabela 17. Podział biznesu na 23 „komórki”. Źródło: Journal of Operational Risk 2006, "LDA at work: Deutsche Bank's approach to quantifying operational risk", F.Aue, M. Kalkbrener

Kategoria "Linia wsparcia" (czyli inna) powinna mieć wystarczająco dużo wewnętrznych danych o stratach, które są potrzebne do budowy stabilnego modelu. Kwestia wyboru „komórki” jest równie ważne jak znalezienie rozkładu, który będzie pasował do danych.

Generowanie scenariuszy najczęściej odbywa się w formie warsztatów. Uczestnikami warsztatów powinni być menedżerowie biznesu, menedżerowie ryzyka oraz pracownicy (eksperci) o znaczącej wiedzy i zrozumienia biznesu oraz środowiska, w których działają. Scenariusze powinny być przeprowadzane w każdej „komórce”, przez managera ryzyka lub niezależnego mediatora – analityka departamentu ryzyka. Uczestnicy warsztatów przy omawianiu środowiska biznesowego czy praktyk biznesowych powinni korzystać ze wskazówek i pomocy opartej na przykładach zewnętrznych.

Przykład.

W banku, przy sprzedaży obligacji zamiennych pracownik niewłaściwie obiecuje klientowi odkupić je z powrotem po określonej cenie. Rynek „porusza się” w złym kierunku, a bank jest zobligowany do honorowania zobowiązań. W rezultacie, bank ponosi stratę. Pytanie na warsztatach: Czy podobna sytuacja występuje w waszym banku? Jeśli tak, jaka jest potencjalna wielkość straty i jak często może się zdarzyć?

Ten scenariusz będzie generowany, w „komórce” dla typu zdarzenia: klienci, produkty i praktyki operacyjne. Po rozważeniu realnych możliwości, uczestnicy warsztatów uzgadniają

scenariusz z tym związany. Jeśli mamy więcej niż jeden scenariusz, to możemy łączyć wartości strat.

Należy pamiętać, że scenariusz nie jest potencjalną stratą a jedynie bada wrażliwość aktualnego środowiska biznesowego pod kątem ryzyka.

6.3. Scenariusze w ramach metodologii sbAMA

Wyobraźmy sobie, że bank chce wykorzystać zaawansowaną metodologię Advanced Measurement Approach (AMA) do pomiaru ryzyka operacyjnego - może to być wymagane np.: dla wyliczenia wymogów kapitału regulacyjnego Filaru I lub wewnętrznej adekwatności kapitałowej ICAAP w ramach regulacyjnego Filaru II. W tym celu wdrożył system zbierania i przechowywania danych o zaistniałych stratach. Proces zbierania danych powinien trwać wiele lat, aby zapewnić wystarczająco dużą liczbę obserwowanych straty do opracowania modelu statystycznego typu Loss Distribution Approach (LDA). Inną alternatywą, zajmującą o wiele mniej czasu, jest budowa scenariuszy opartych na opinii ekspertów. Są to tzw. scenariusze sbAMA. Oczywiście z biegiem czasu, gdy będzie rosła ilość danych wewnętrznych, bank powinien wziąć pod uwagę integrację obu tych podejść (Dutta 2010).

Budowa scenariuszy sbAMA polega na pomysśle, zwanym również metodą aktuarialną, polegającym na połączeniu dwóch wymiarów zdarzeń - częstotliwości i dotkliwości. Ten sam pomysł leży u podstaw metody LDA wykorzystywanej do analizy danych historycznych. To połączenie wymiarów realizowane jest poprzez obliczenie oddzielnie rozkładu częstości zdarzeń, oddzielnie rozkładu dotkliwości zdarzeń a następnie na tej podstawie łącznego rozkładu strat. Różnica pomiędzy sbAMA, a LDA polega na tym, że szacowanie rozkładów częstości i dotkliwości opiera się na opinii ekspertów prognozujących możliwość wystąpienia zdarzeń. Banki w oparciu o te scenariusze budują modele pozwalające skwantyfikować ryzyko operacyjne. Scenariusze budowane przez ekspertów dotyczą zarówno samej możliwości wystąpienia zjawiska – tzw. informacja jakościowa, jak i ilościowej opinii na temat prawdopodobieństwa wystąpienia (częstotliwości) oraz potencjalnej wartości straty ekonomicznej (dotkliwości) – informacja ilościowa.

Opinie ekspertów wykorzystuje się nie tylko w sytuacji gdy brak jest danych historycznych ale również gdy one występują traktując je jako informację o przyszłości. Wykorzystanie ekspertów do wygenerowania odpowiednich danych opiera się na przekonaniu o konieczności uzupełnienia danych historycznych dodatkowymi źródłami danych. Użyteczność tego typu niezależnej informacji dotyczącej przyszłości zależy od wielu czynników związanych z procesem pozyskania danych od ekspertów, które będą opisane poniżej. Przepisy nadzorcze dopuszczają korzystanie ze skwantyfikowanych opinii eksperckich. Trzeba jednak zauważyć, że eksperci są innym źródłem informacji niż wewnętrzna, a także zewnętrzna baza danych. Wartości uzyskiwane z tego źródła mogą istotnie różnić się od wartości zbieranych tradycyjnymi metodami opartymi na ocenie strat historycznych.

W zależności od tego czy dysponujemy wyłącznie danymi w postaci opinii ekspertów, czy też dodatkowo mamy dane historyczne o rzeczywistych zdarzeniach i musimy połączyć oba źródła danych, opinie będą traktowane inaczej:

- w przypadku dysponowania pewnymi danymi na temat zdarzeń, rozkład uzyskany na podstawie opinii ekspertów, może być w postaci prawdopodobieństwa a priori czyli czynnika korekcyjnego do prawdopodobieństwa uzyskanego na podstawie danych historycznych
- w przypadku, gdy nie dysponujemy danymi historycznymi lub są one szczątkowe, rozkład prawdopodobieństwa może nieć postać „opisu stanu natury” czyli będzie pełnił funkcje podstawowego źródła informacji.

Bardzo ciekawie wygląda porównanie wartości strat szacowanych na podstawie scenariuszy eksperckich z danymi historycznymi uzyskane w różnych bankach.

W tabeli poniżej znajdują się porównania szacunków ekspertów z wynikami uzyskanymi na podstawie wewnętrznych danych. Wyniki zostały rozbite na obszary geograficzne („boczek” tabeli) oraz szacowany percentyl rozkładu („główka” tabeli). W tabeli oprócz samej wartości mediany podane został rozrzut kwartyłowy.

Tabela		95%-percentyl z 20 najwyższych scenariuszy podzielony przez 95%-percentyl z 20 najwyższych strat wewnętrznych	„1-na-1000 lat” strata wygenerowana ze scenariuszy podzielony przez 95%-percentyl z 20 najwyższych strat wewnętrznych
Cały świat	Mediana (25%-75% percentyl)	5.6 (1.6-29.0)	27.2 (3.8-76.1)
Australia	Mediana (25%-75% percentyl)	12.3 (5.0-34.6)	22.9 (14.7-76.1)
Europa	Mediana (25%-75% percentyl)	3.5 (1.4-25.3)	24.7 (3.8-65.7)
Japonia	Mediana (25%-75% percentyl)	17.6 (5.6-52.3)	43.3 (5.6-109.6)
Ameryka Północna	Mediana (25%-75% percentyl)	2.5 (0.7-23.6)	9.8 (3.6-42.4)

Tabela 18. Porównanie ocen eksperckich z danymi historycznymi. Źródło (BCBS 2009a)

I tak w Europie szacowana mediana ilorazu 99%-centyla (co odpowiada 95%-centylowi z 20 najwyższych strat) uzyskanego ze scenariuszy eksperckich w porównaniu do 99%-centyla uzyskanego z danych wewnętrznych wynosi 3.5 . Zakres kwartyłowy wynosi 1.4-25.3 co pokazuje, że szacunek jest niedokładny ale istotnie różny od 1.0.

Podobne wnioski można wyciągnąć porównując 99.9%-centyl (czyli stratę 1-na-1000 lat) z 99%-centylem uzyskanym z danych. Wynik 24.7 w zakresie 3.8-65.7 jest również bardzo duży, nawet jeżeli przeliczymy go do wartości standardowej czyli na 99.9%-centyl obserwowanych danych historycznych. W przypadku „dużego polskiego banku” nie było możliwości policzenia tak dużego percentyla bezpośrednio, dlatego trzeba to wykonać w oparciu o model kalibrowany na danych

historycznych. Przy założeniu, że duże straty mają rozkład uogólniony Pareto GPD (Makarov 2006) (zgodnie z twierdzeniami o rozkładzie wartości ekstremalnych ETV) wynik powinien wynosić ~ 8.5 .

Aby umożliwić łączenie wyników eksperckich i historycznych w ramach wspólnej metody wyniki z symulacji sbAMA powinny być statystycznie zgodne z tymi wynikającym z LDA co zazwyczaj nie jest spełnione. Istnieje kilka systemów analitycznych pozwalających na „łączenie” danych z obu źródeł. Jedną z takich technik integracji LDA i sbAMA jest wnioskowanie bayesowskie (Carvalho 2008).

6.4. Wykorzystanie opinii ekspertów do budowy modelu ryzyka operacyjnego

Aby zapewnić zgodność modelu z obowiązującymi przepisami, bank powinien uzupełnić posiadaną informację potrzebną do budowy modelu LDA poprzez dołączenie scenariuszy ekspertów. Po pierwsze, dyrektor departamentu ryzyka (ORM) powinien decydować, kto będzie występował jako ekspert podczas tworzenia różnych scenariuszy. Subiektywny charakter tego przedsięwzięcia, może spowodować, że ORM powinien zasięgnąć opinii wielu ekspertów. W większości banków, analiza scenariuszy jest prowadzona przy współpracy z pracownikami odpowiednich linii biznesowych. ORM prosi dyrektorów poszczególnych linii biznesowych o dostarczenie listy pracowników o odpowiednich umiejętnościach i doświadczeniu, którzy mogliby wziąć udział w budowie i analizie scenariuszy.

Zgodnie z wewnętrznymi wymogami zarządzania ryzykiem najczęściej szef linii biznesowej ponosi ostateczną odpowiedzialność za zarządzanie ryzykiem operacyjnym w codziennej działalności jednostki oraz za zapewnienie prawidłowego i efektywnego środowiska kontroli. W konsekwencji, powinien być włączony do przeglądu, weryfikacji i zatwierdzania wyników procesu oceny.

To prowadzi do drugiego pytania. Jak ORM powinien organizować sesje poświęcone analizie scenariuszy?

Rozważmy następujący wariant: w warsztatach, które odbywają się z ekspertami, biorą udział szefowie linii biznesowych, uczestniczą w dyskusjach i debatach, prowadzących do finalnych oszacowań. Takie rozwiązanie ma swoje zalety: obok rozwiązania kwestii odpowiedzialności, jest mniej czasochłonne niż indywidualne sesje, a uczestnicy mogą wymieniać się informacjami w celu zwiększenia dokładności szacunków. Ale warsztaty to także duże ryzyko uzyskania błędnych wyników. Podejmowanie decyzji w grupie charakteryzuje się wpływem czynników psychologicznych, takich jak, na przykład: pojawienie się w dyskusji liderów, którzy mają silny wpływ na innych, mogą oni oczywiście działać na rzecz jedności grupy, chociaż nie zawsze zgadzają się z innymi. Jest to szczególnie ważne, zwłaszcza, że często w warsztatach reprezentowane są różne poziomy organizacyjne banku. Kolejny czynnik psychologiczny jest powiązany z działaniami, które można wyjaśnić nawiązując do pojęć z teorii gier. Niektórzy eksperci umyślnie przeszacowują pewne fakty próbując wpływać na innych i kierując konsensus na określone wartości (Fellner 1965).

Zanim opinie zostaną połączone, muszą one być wyrażonych w formie ilościowej. W istocie, jak stwierdził Hogarth (1975), "człowiek jest selektywnym, systemem sekwencyjnego przetwarzania informacji o ograniczonej pojemności. [...] źle dostosowanym do oceny rozkładu prawdopodobieństwa". Niestety, wiele rozwiązań problemu łączenia opinii wymaga, aby opinia

każdej osoby była zakodowany w postaci subiektywnego rozkładu prawdopodobieństwa. W konsekwencji, sposób budowania scenariuszy wpływa w istotny sposób na pozyskiwaną informację.

Analiza Scenariuszy pod kątem obciążeń procesu zbierania opinii od ekspertów

	Razem		Australia		Europe		Japonia		Północna Ameryka	
Liczba banków	42		5		20		7		10	
	#	%	#	%	#	%	#	%	#	%
Reprezentatywność	17	40%	1	20%	7	35%	4	57%	5	50%
Dostępność	13	31%	2	40%	6	30%	2	29%	3	30%
Zakotwiczenie	11	26%	2	40%	2	10%	1	14%	6	60%
Motywacyjność	14	33%	2	40%	5	25%	2	29%	5	50%
Proporcji	11	26%	2	40%	3	15%	2	29%	4	40%
Inne	5	12%	0	0%	2	10%	0	0%	3	30%

Tabela 19. Analiza obciążeń procesu elicytacji. Źródło (BCBS 2009b)

Te obciążenia znajdują odzwierciedlenie w głównych heurystykach stosowanych przez ekspertów przy ocenie prawdopodobieństwa w warunkach niepewności. Należą do nich:

- Dostępność. Polega na tym, że ludzie oceniają częstość zdarzeń na podstawie podobnych sytuacji, nie doceniają prawdopodobieństwa zdarzeń mniej znanych (Tversky i Kahneman 1974)
- Zakotwiczenie. Polega na tym, że ludzie zmieniają swoje oszacowania w zależności od tego, jakie podano im właściwości wyjściowe, które często używane są jako punkt wyjścia, i na tym tle postrzeganą wartość dostosowują w górę lub w dół. Niestety, ta regulacja często prowadzi do błędów, i produkuje systematyczne obciążenie oszacowań (O'Hagan 1998 r.; Winkler 1967).
- Reprezentatywność, czyli przypisywanie do danej kategorii na podstawie kilku cech uważanych za reprezentatywne inaczej. tendencja do powiązania tego wydarzenia z innym podobnym i czerpanie z tego szacunków prawdopodobieństwa. Jednym z błędów tej heurystyki nazywa się prawem małych liczb. Ludzie zazwyczaj ignorują zmienność w małych próbach (Kahnemann, Slovic i Tversky 1982).
- Proporcja i kadrowanie. Wyniki z ankiet (tj. oceny prawdopodobieństwa) są wrażliwe na sformułowanie i kolejność użytych pytań (Pahlman i Riabacke 2005).

Obok obciążeń specyficznych dla każdej heurystyki poniższe obciążenia występują zawsze:

- konserwatyzm – ekspert nie docenia konieczności dużej korekty wstępnych założeń;
- „prawo małych liczb” – ekspert traktuje małą próbkę jako reprezentatywną i nie docenia rzadkich zdarzeń, skutkuje to szacowaniem większej zmienności, niż wynika to z rozkładu losowego

- efekt myślenia wstecznego – ekspert traktuje nawet mało prawdopodobne zdarzenia, które akurat zaszły, jako typowe.

Bardzo ważne jest określenie zakresu pytań wykorzystywanych przy zbieraniu informacji. Aby uniknąć bezpośredniego szacowania prawdopodobieństwa, które nota bene nie jest intuicyjne, ORM powinien przygotować pytania, dopasowane do sposobu myślenia "non-statisticians". Rozwiązaniem jest wprowadzenie pytań o potencjalne skutki strat dla każdego scenariusza czy też pytania w postaci: „ile czasu będziemy czekać na podobne zdarzenie” lub „ile czasu będziemy czekać na zdarzenie o skutkach porównywalnych lub wyższych?” Takie pytania koncentrują się na pojęciu średniego czasu oczekiwania i mogą być łatwiejsze do kwantyfikacji (Steinhoff i Baule 2006).

6.5. Integracja LDA i sbAMA

Jeśli chodzi o połączenie metod sbAMA i LDA, banki używają jednej z dwóch metod integracji, które znacznie różnią się między sobą i które można opisać jako:

- Ex-ante, która polega na połączeniu wyników na poziomie szacowania parametrów rozkładów częstotliwości i dotkliwości przed wyliczeniem ostatecznego wyniku. Inaczej mówiąc, źródła informacji są łączone w celu uzyskania szacunków parametrów rozkładów. Dopiero na podstawie tych parametrów wyliczane są wartości ryzyka.
- Ex-post, która polega na połączeniu różnych źródeł na poziomie wyliczonych ryzyk i wyznaczaniu łącznej straty, poprzez agregowanie wyniku. Zazwyczaj, polega to na niezależnym obliczaniu strat w oddzielnych modelach. Źródła informacji łączone są po wyliczeniu wartości strat przy pomocy N-krotnego spłotu rozkładu dotkliwości zdarzeń. Obliczenie spłotu rozkładu metodą analityczną jest bardzo trudne, dlatego korzysta się z numerycznych rozwiązań opartych na strategii Monte Carlo. W praktyce wyniki są zwykle dyskretyzowane i numeryczne spłoty są stosowane do każdego z przedziałów określających rozkłady;

Reguły integracji ex-post możemy przedstawić w postaci bardziej formalnej. Rozważmy losowy wektor obserwacji $X = (X_1, X_2, X_n...)$, których gęstość prawdopodobieństwa zadana jest funkcją parametryczną $Lik(X | \theta)$, dla danego wektora parametrów $\theta = (\theta_1, \theta_2, \theta_k...)$. Załóżmy dalej, że parametr θ sam ma rozkład prawdopodobieństwa $\pi(\theta)$, zwany prawdopodobieństwem a`priori.

Wtedy, twierdzenie Bayesa można sformułować następująco:

$$Lik(X, \theta) = Pr(X|\theta)\pi(\theta) = \hat{\pi}(\theta|X)Pr(X)$$

gdzie:

$\hat{\pi}(\theta|X)$ prawdopodobieństwo parametru θ przy obserwowanym wektorze X
(zwane prawdopodobieństwem aposteriori)

$Lik(X, \theta)$ łączne prawdopodobieństwo obserwacji i parametru

$Pr(X)$ brzegowe prawdopodobieństwo wektora obserwacji X

Prawdopodobieństwo a`posteriori czyli prawdopodobieństwo parametru θ przy obserwowanym wektorze X możemy zapisać, jako iloczyn:

$$\hat{\pi}(\theta|X) \propto \pi(\theta) Pr(X|\theta)$$

W zakresie ryzyka operacyjnego można przyjąć, że eksperci oceniają: formę rozkładu czyli wybierają odpowiednią rodzinę $Pr(.)$ oraz wartość parametru θ . Prawdopodobieństwo zaobserwowania wektora danych historycznych $Pr(X|\theta)$ można uzyskać stosując standardową metodologię LDA budując odpowiedni model na rzeczywistych stratach - można wykorzystać straty wewnętrzne lub mieszanie danych wewnętrznych i zewnętrznych (co jednak wymusza stosowanie odpowiedniej procedury skalującej). Załóżmy, że istnieje consensus co do rodziny rozkładów $Pr(.)$, wówczas aby zastosować wnioskowanie Bayesa możemy zastosować następujące podejścia:

- Rozkład a`posteriori $\pi(\theta|X)$ powinien zostać zdefiniowany tak, aby można było stosować go w symulacjach Monte Carlo do wyliczenia wartości ryzyka ;
- Rozkład a`priori $\pi(\theta)$ powinien być szacowany na podstawie scenariuszy tzn. opierając się na opinii ekspertów.

Wnioskowanie Bayesa (Peters 2006) ma wiele użytecznych właściwości, dlatego też często stosowane jest do modelowania ryzyka operacyjnego:

- Zapewnia podstawę teoretyczną stosowania formalnych metod statystycznych łączenia dwóch heterogenicznych źródeł informacji - subiektywne opinie ekspertów i zebranych „twardych” danych historycznych;
- Zapewnia przejrzystość kontroli audytu wewnętrznego na potrzeby nadzorca, ponieważ umożliwia oddzielną analizę źródeł informacji;
- Dobrze nadaje się do sformalizowania istoty ryzyka operacyjnego opierającego się zarówno na obserwacji zdarzeń jak i niepewnych założeniach, co do parametrów rozkładów.

6.6. Techniki RCSA

Zasadniczo istnieją trzy główne techniki zbierania informacji w ramach RCSA, a mianowicie:

- warsztaty,
- kwestionariusze i ankiety
- techniki hybrydowe.

Każda z tych metod ma swoje zalety i wady, które uwidaczniają się w sposobie realizacji RCSA aczkolwiek powinno uwzględniać się metodykę zarządzania, kulturę, środowisko pracy, wielkość i złożoność struktury organizacyjnej, rozproszenie geograficzne. Jak pokazuje doświadczenie

najważniejszym warunkiem, jest istnienie powszechnej zgody co do koncepcji RCSA od szczybla zarządzania do niższych poziomów wykonawczych.

Warsztaty

Metoda warsztatowa RCSA może pomóc ominąć tworzenie szczegółowej dokumentacji związanej z procesem pozyskiwania danych. Warsztat jest sposobem pozwalającym zaangażować ludzi w rozmowy na temat ryzyka, kontroli i w ten sposób określić poprawki systemu. W bardziej sformalizowanej formie metoda ta może być stosowana w powiązaniu z listą kontrolną procesów biznesowych i przeglądów proceduralnych.

Korzyści wynikające z podejścia warsztatów obejmują:

- Podnoszenie świadomości wzajemnych zagrożeń funkcjonalnych i hierarchicznych;
- Umożliwienie oceny i poprawy mechanizmów kontrolnych w sposób „miękki”, np. komunikacja, szkolenie i podział odpowiedzialność
- Zapewnienie możliwości transferu umiejętności zarządzania ryzykiem w całej organizacji.

Definicja eksperta

Podstawowym problemem związanym z samooceną jest udział ekspertów. Ekspertem jest osoba mająca biznesową wiedzę o możliwych zdarzeniach. Trzeba jednak zdać sobie sprawę, że doświadczenie merytoryczne w zakresie tematyki obejmującej badanie nie oznacza tego samego co doświadczenie w rachunku prawdopodobieństwa i statystyki. Uczestnicy warsztatów budujący scenariusze w ramach metodyki zaawansowanej (AMA) są zwykle kierownikami, doradcami pracującymi w jednostkach sprzedażnych, kontroli lub innymi pracownikami posiadającymi odpowiednie doświadczenie biznesowe. Jednym z głównych problemów związanych z wyborem ekspertów jest fakt, że osoba ta może nie mieć doświadczenia z miarami w rozumieniu probabilistycznym. Nie można od niej wymagać ścisłego kierowania się „matematycznymi formułami”, a co za tym idzie, proces kwantyfikacji informacji podlega naturalnemu zaburzeniu związanemu z procesem pomiaru.

Konsekwencją jest fakt, że wielkości uzyskiwane od eksperta nie zawsze muszą być wiarogodne. Im bardziej intuicyjne są narzędzia pomiaru, a więc ograniczenie się do prostych pojęć typu: średnia, częstość wystąpienia raz na „n” lat itp. tym bardziej precyzyjne są wyniki. Próba oceny miar rozrzutu jak np. odchylenia standardowego z reguły prowadzi do dużych błędów. Przy okazji warto zauważyć że częstość zdarzeń rzadkich również wymyka się intuicji. W literaturze spotkać można graniczną częstość raz na 10 lat, jako częstość, poniżej której ekspert nie jest w stanie dokładnie opisać zdarzenia posługując się swoją wiedzą.

Ogólne zalecenia co do procedury prowadzenia warsztatów:

- ekspert powinien opisać rozkład prawdopodobieństwa poprzez parametry;

- ekspert powinien dokładnie określić swój związek ze zdarzeniem, który może wpłynąć na ocenę;
- powinno przeprowadzić się szkolenia „kalibrujące”;
- trzeba dokumentować nie tylko wynik uzyskany od eksperta ale również dodatkowe informacje (np. uwagi).

Czasami warsztaty organizowane są z udziałem mediatora, który pomaga ekspertom formułować wiedzę w kategoriach prawdopodobieństwa. Dlatego konieczne jest dokładne zdefiniowanie zarówno wyników kwantyfikacji wiedzy eksperckiej jak i metodologii stosowanej do jej pozyskania. Zazwyczaj jako mediatorów do warsztatów wybiera się pracowników departamentu posiadających doświadczenie w dziedzinie rozpatrywanej sprawy. Alternatywnie, można przyjąć normatywnych ekspertów czyli pracowników departamentu ryzyka, którzy są przeszkoleni w zakresie metod aktywizacji lub posiadają umiejętności szacowania parametrów w kategoriach prawdopodobieństwa.

Kadane i Wolfson (1998) twierdzą, że celem mediatorów jest aktywizacja warsztatów tak aby przełożyć zdania ekspertów w danej dziedzinie na kategorie prawdopodobieństwa przy jednoczesnej redukcji informacji mogącej zaburzyć proces.

Analiza scenariuszy w formie warsztatów wymaga opracowania odpowiednich pytań w zależności od wiedzy ekspertów z zakresu statystyki i rachunku prawdopodobieństwa. Odpowiednie przygotowanie warsztatów ma zapobiec wystąpieniu błędów i obciążeń. Szczególne znaczenie mają ćwiczenia normalizujące odpowiedzi – kalibracja. Prowadzi to do wyłapywania odstępstw i błędów systematycznych.

Świadome, lub nie rozbieżności pomiędzy uczestnikami warsztatów wpływają nie tylko z ich wiedzy i przekonań ale często są wyrazem uprzedzeń. Takie uprzedzenia powstają z ograniczeń pamięci czy zdolności kojarzenia, ale również wtedy, gdy uczestnik ma interes w tym aby wpłynąć na wynik procesu kwantyfikacji (Spetzlera i von Holstein, 1975, p345). Takie czynniki, powodujące obciążenia wyników powinny być przedmiotem analizy na etapie raportu końcowego, a ich wyniki włączane do metodyki prowadzenia warsztatów. Do typowych czynników mogących wpłynąć na wynik warsztatów może być np. obecność managera, który ma inną wagę głosów od pozostałych uczestników.

Wybór ekspertów

W wielu przypadkach, analityk departament ryzyka może znać odpowiednich ekspertów zarówno wewnętrznych pracujących w banku, jak i zewnętrznych. Jednak może być konieczne, powołanie odpowiednich ekspertów w danej dziedzinie, którzy nie są znani analitykowi. Jak ustalić, kim są eksperci i jak można zapewnić, żeby eksperci posiadali odpowiednie kwalifikacje wymagane do dokonania szacunków parametrów zdarzenia?

Obecnie nie ma bazy danych ani rejestru ekspertów związanych z wymaganiami dotyczącymi szacowania ryzyka operacyjnego w bankach. Wobec braku rejestru, przedstawionych zostanie poniżej kilka wskazówek, którymi można się kierować przy wyborze ekspertów.

Analitik departamentu ryzyka powinien zawsze zaczynać od definicji problemu. Określenie dziedziny problemu jest podstawą do wyboru eksperta. W zależności od celów analizy zaleca się przeprowadzanie analiz w grupie nie mniej niż trzech, czterech ekspertów.

Źródła związane z przemysłem atomowym (Hukki 2008) sugerują, że najlepsze rezultaty uzyskuje się zazwyczaj w przypadku trzech ekspertów. Z wyjątkiem niektórych analiz, nigdy nie jest zalecane wykorzystanie jednego eksperta, ponieważ istnieje bardzo poważne ryzyko obciążenia wyników tzw. niebezpieczeństwo, że wybór tego jednego eksperta może nie odzwierciedlać rzeczywistego rozkładu opinii dla danej dziedziny problemu. Wybór jednego eksperta może spowodować niedokładne i nie powtarzalne oszacowania prawdopodobieństwa. Korzystanie z wielu ekspertów zwiększa również testowalność analiz np. Meyer i Booker, (1990) sugerują techniki osłabienia obciążeń poprzez wykorzystanie metody losowania wielopoziomowego, w metodzie tej eksperci, wybrani są z różnych źródeł (np. krajowe laboratorium ekspertów, naukowców, ekspertów NRC, itp.).

Aktywacja

Aktywacja to proces formułowania wiedzy i przekonań w warunkach niepewności tak aby wyobrażenia o ilościowych wielkościach zdarzenia można było wyrazić w postaci rozkładu prawdopodobieństwa. W kontekście analiz bayesowskich, aktywizacja najczęściej pojawia się jako metoda określania wag prawdopodobieństwa dla jednego lub większej liczby nieznanymi parametrów modelu statystycznego. Duża część literatury na temat aktywizacji dotyczy sformułowania rozkładu prawdopodobieństwa w sytuacji, gdy nie ma odpowiednich danych, na których można byłoby się oprzeć, a mimo to trzeba zbudować odpowiedni model. Inaczej mówiąc, trzeba określić wartości wstępne i uzyskać wyniki mając świadomość umowności założeń co do "prawdziwej" wartości. Ważne jest prześledzenie sposobu w jaki model propaguje niepewność danych wejściowych na oszacowania niepewności wyniku.

Wygodnie jest myśleć o aktywizacji jako zadaniu mediatora, który pomaga ekspertom przekształcić wiedzę do postaci prawdopodobieństwa. W tym kontekście można odwołać się do schematu Bayesa. Formalizuje on sposób w jaki wiedza ekspertów, która jest odzwierciedleniem aktualnego stanu jego wiedzy, wyrażana się w probabilistycznym formie i jaki wpływ mogą mieć na to czynniki zewnętrzne kształtujące „aktualny stan wiedzy”.

Jeśli ekspert bardzo dobrze zna pojęcia statystyczne, to może nie potrzebować pomocnika, ale taka sytuacja rzadko występuje w praktyce.

Warsztaty bezpośrednie są najczęściej używaną formą pozyskiwania wiedzy od ekspertów. W metodzie tej eksperci dyskutują różne aspekty procesów bankowych pod kątem specyfiki możliwych zdarzeń oraz konsekwencji tych zdarzeń. W zasadzie rozróżnia się dwa typy warsztatów:

1. Warsztaty zamknięte – podczas których prowadzący przedstawia pytania przygotowane wcześniej i próbuje uzyskać odpowiedzi od wszystkich uczestników.
2. Warsztaty otwarte – podczas których prowadzący próbuje wyciągnąć wnioski podczas otwartej dyskusji, główne zadanie prowadzącego to opis prowadzonej dyskusji.

Zazwyczaj warsztaty przebiegają w ten sposób, że w pierwszej części zaczyna się od przygotowanych pytań w ramach metodologii „zamkniętych warsztatów”. W trakcie odpowiedzi zarysowują się różnice zdań, które prowadzą do otwartej dyskusji.

Inną metodą zbierania informacji jest metoda kwestionariuszowa. Pozwala ona włączyć do procesu pozyskiwania danych większą grupę ekspertów bez konieczności wydłużenia tego procesu w czasie. Rezultaty uzyskiwane na podstawie kwestionariuszy zależą od dwóch głównych czynników:

1. Budowy samego narzędzia jakim jest kwestionariusz
2. Rzetelności respondentów

Dobrze zaprojektowany kwestionariusz wpływa zarówno na rzetelność udzielanych odpowiedzi jak i pomaga ograniczyć błąd związany z tą formą zbierania informacji.

Schemat prowadzenia warsztatów składa się z kilku etapów:

- Pierwszym etapem jest wybór ekspertów, i szkolenia (kalibracji), podczas którego szkoli się uczestników tak aby przykładali jednakową wagę do różnych czynników środowiska oraz innych aspektów problemu. Jednym z narzędzi mogących wspomóc przygotowania do warsztatów na tym etapie może być wybór literatury czy wręcz doniesień prasowych na dany temat.
- Następnie następuje proces kwantyfikacji wiedzy. Eksperti różniący się między sobą mogą wymieniać swoje doświadczenia ale na ogół trudno jest doprowadzić do zmiany zdania. Czasami, wyjściem z sytuacji może być próba skierowania uwagi uczestników na warunki skrajne co powoduje zwrócenie uwagi na zdarzenia rzadkie.
- Kolejnym etapem jest omówienie różnych właściwości rozkładów prawdopodobieństwa i próba dopasowania rozkładu do uzyskanych opinii. W praktyce na tym etapie następuje dalsze uzgodnienie opinii. Na podstawie wyznaczonego rozkładu można policzyć konsekwencje wyboru i zderzyć je z pierwotnymi opiniami.
- Aktywizacja jest prawie zawsze procesem iteracyjnym, a czwarty etap polega na ocenie adekwatności aktywizacji, z możliwością powrotu do drugiego etapu, który może wywołać dalszą dyskusję ekspertów.

Przy okazji kwantyfikacji wiedzy eksperckiej warto jest przywołać metodologię opracowaną przez grupę badaczy amerykańskich i znaną pod nazwą Metoda Delphi. Metoda Delphi jest metodologią współpracy grupowej, która skupia się na badaniu i filtracji opinii ekspertów. Jej podstawową cechą jest anonimowość odpowiedzi, sprzężenie zwrotne dotyczące indywidualnego lub zespołowego spojrzenia, a także możliwość modyfikacji wcześniejszych opinii przez respondentów (Lindqvist 2007).

Badania Delphi są raczej skomplikowaną procedurą, która obejmuje przygotowanie, badania w dwóch lub więcej rundach oraz analizy finalnej, gdy badanie zostało zakończone. Bardzo dużo zależy od przekonania uczestników co do skuteczności stosowania tej metody.

W literaturze propagującej tę metodę znaleźć można opis następujących prawidłowości:

- przewidywania grupy były bardziej prawdopodobne niż jednostki,
- stanowiska poszczególnych jednostek miały tendencję do konwergencji w miarę trwania badania. Ponadto błąd prognozowania z użyciem Delphi w porównaniu z innymi metodami (tj. jakościowymi i nieustrukturalizowanym prognozowaniem subiektywnym) jest znacznie niższy. W badaniach dotyczących przewidywania cen na przestrzeni trzech lat wyniósł on 3–4% dla Delphi, 10–15% dla metod ilościowych i ok. 20% dla prognoz subiektywnych (Schroeder, 1977) [za: 3].

Niemniej jednak trzeba zdawać sobie sprawę z mocnych i słabych stron metody tak, że metoda ta nie może być stosowana w każdym przypadku. Jest ona przydatna dla oceny nowych tematów szczególnie w sytuacjach, które można wytłumaczyć bardzo krótko. Oznacza to, że przy analizie złożonych tematów, lepiej jest korzystać z innych metod, takich jak warsztaty i wziąć pod uwagę metodę Delphi jako metodę pomocniczą pozwalającą porządkować pojedyncze kawałki informacji.

W polskich bankach metoda ta nie jest wykorzystywana głównie z tego powodu, że wymaga bardzo głębokiego zaangażowania się uczestników – ekspertów – w proces kwantyfikacji. Natomiast w bankach ryzyko traktowane jest jako proces wspomagający sprzedaż i bardzo trudno o utrzymanie odpowiedniego poziomu współpracy różnych osób wymaganych przez tę metodę.

Parametry rozkładów oceniane przez ekspertów

Eksperci najczęściej szacują parametry rozkładów na podstawie szcunków podstawowych statystyk takich jak:

- wartość przeciętna – wartość średnia, mediana, modalna; wybór poszczególnych parametrów zależy od rozkładu - dla rozkładów symetrycznych bywa to wartość średnia, dla niesymetrycznych lepiej wybrać medianę, problem są rozkłady wielomodalne.
- wartość rozrzutu – nie poleca się bezpośredniej estymacji wariancji (mało intuicyjna wielkość), znacznie lepiej szacować przedział wiarygodności (lub ufności), Można to osiągnąć metodą: stałych lub zmiennych przedziałów. Często szacowanie rozrzutu odzwierciedla stopień niepewności eksperta a nie ocenianego zjawiska.
- szacowanie „krajowych ogonów” rozkładów – czyli wartości ekstremalnych.

Od pewnego czasu podejmowane są próby usystematyzowania procesu budowy scenariuszy w ramach ryzyka operacyjnego. W roku 2008 Bazylejski Komitet Nadzoru Bankowego BCBS przedstawił propozycję platformy do budowy i analiz scenariuszy publikując szablony, które są najbardziej odpowiednie do zbierania danych. Powstały one w wyniku konsultacji z wieloma bankami europejskimi i nieeuropejskimi.

Najważniejsze szablony to: podejście indywidualne, podejście interwałowe i percentylowe.

W podejściu indywidualnym eksperci budują scenariusze dla poszczególnych zdarzeń i przypisują im indywidualne wagi związane z prawdopodobieństwem wystąpienia danego zdarzenia.

Przy podejściu interwałowym i percentylowym szacowaniu podlegają całe grupy zdarzeń w ramach poszczególnych procesów. Skutki zdarzeń określa się z dokładnością do pewnej jednostki w postaci

Institution Name: _____ Units of Currency (eg thousands, millions): _____

Section 1. Scenario Reference Number	Section 2.												Section 3. Currency ¹	Section 4. Basel Business Line ²	Section 5. Internal Business Line	Section 6. Basel Event Type ³	Section 7. Used in AMA Model (Y/N)	
	Interval 1				Interval 2				Interval 3									Add additional intervals as necessary
	Severity		Frequency		Severity		Frequency		Severity		Frequency							
	Low	High	Low	High	Low	High	Low	High	Low	High	Low	High						

Tabela 21. Kwestionariusz do zbierania opinii ekspertów metodą przedziałową. Źródło: “2008 Loss Data Collection Exercise”, Accord Implementation Group Operational Risk, BCBS 2009

Wynikiem stosowania podejścia przedziałowego są zagregowane szacunki częstotliwości serii różnych zakresach strat wynikających ze zdarzeń w danej grupie.

2. Podejście indywidualne

Eksperti oceniają dotkliwość przewidywanej pojedynczej straty.

Institution Name: _____ Units of Currency (eg thousands, millions): _____

Section 1. Scenario Reference Number	Section 2. Frequency	Section 3. Loss Amount	Section 4. Currency ¹	Section 5. Basel Business Line ²	Section 6. Basel Business Line	Section 7. Basel Event Type ³	Section 8. Used in AMA Model (Y/ N)	Section 9. Brief Description of Loss

Tabela 22. Kwestionariusz do zbierania opinii ekspertów metodą ryzyk indywidualnych. Źródło: “2008 Loss Data Collection Exercise”, Accord Implementation Group Operational Risk, BCBS 2009

Wynikiem uzyskiwanym z indywidualnego podejścia są wagi oszacowania związane z prawdopodobieństwem wystąpienia zdarzenia dla każdego scenariusza.

Przegląd źródeł danych nt. zdarzeń operacyjnych.

Przed przystąpieniem do zorganizowania warsztatów, w celu zebrania opinii ekspertów, konieczny jest przegląd dostępnej historii o możliwych wydarzeniach i rodzaju działalności w zakresie opisanym przez wytyczne, co do obszaru „Linii biznesowej/typu zdarzeń”, a mogących mieć wpływ na prawdopodobieństwo zdarzenia. Przegląd ten powinien określać środowisko, w którym może zajść

zdarzenie i które będzie pomocne w przypadku pytań, precyzujących opisanie wskaźnika „szkodowości” zdarzenia. Pozyskanie danych od ekspertów powinno być realizowane, jeżeli dodatkowe weryfikowane źródła informacji nie są wystarczające, co do wartości informacji o awariach sprzętu lub błędach człowieka (Boring 2005).

Analitik prowadzący warsztaty powinien sprawdzić, czy istnieją wcześniejsze analizy związane z tym wydarzeniem. Punktem wyjścia dla każdej analizy jest sprawdzenie założeń, modeli, obliczeń, i szacunków ekspertów uzyskanych w trakcie poprzedniej sesji warsztatowej. Niezbędna jest kontrola i weryfikacji istniejących wyników analiz przed przystąpieniem do nowych warsztatów. Wiąże się to również z określeniem częstości prowadzenia warsztatów w danym obszarze.

Identyfikacja nowej informacji nie zawsze jest prostym procesem, w zależności od natury dodatkowych źródeł danych. Źródła danych powinny zostać opisane w następujący sposób:

- Raport o zdarzeniach, w którym zdarzenia powinny zostać poddane przeglądowi pod kątem wiarygodności i kompletności informacji lub prognoz specyficznych dla danej dziedziny w celu ustalenia stopy „szkodowości”.
- W niektórych przypadkach, eksperci mogą pomóc w identyfikacji odpowiednich obszarów. W rzadkich przypadkach, gdy zdarzenie jest bardzo znaczące oraz gdy nie ma wystarczających empirycznych podstawy do oceny ekspertów, departament ryzyka może zlecić dodatkowe badania w celu określenia prawdopodobieństwa zdarzenia.
- Jeżeli zdarzenie może dotyczyć jakichś urządzeń lub oprogramowania niezbędne jest zebranie danych od dostawcy. Dla elementu związanego ze zdarzeniem, wszystkie dostępne dane producenta w zakresie niezawodności powinny być brane pod uwagę. Analitik powinien skontaktować się z producentem w celu ustalenia dostępności określonych danych.
- Dostępne dane z badań zewnętrznych. Poprzednie raporty i inne źródła danych banku należy poddać przeglądowi w celu określenia, czy istniejące wyniki badań charakteryzują podobne zdarzenia.

Dla źródeł informacji, które zawierają wcześniej zebrane i zarejestrowane dane, proces podejmowania decyzji w celu identyfikacji i wykorzystania ich w analizie powinien być następujący:

- Określenie, jaki typ danych będzie pomocny w wyjaśnieniu przyczyn i skutków zdarzenia, co może wpływać na oszacowane prawdopodobieństwa i skutki ilościowe;
- Przegląd i analiza treści informacji;
- Ocena dodatkowych źródeł danych pod kątem użyteczności do szacowania prawdopodobieństwa, i ich wpływu na pozyskiwanie ocen ekspertów.

Ryzyko istotnych zdarzeń.

W przypadku, gdy dostępna informacja a priori jest niewystarczająca, aby można było obliczyć współczynnik „szkodowości”, powinno dokonać się przeglądu istotności potencjalnych ryzyk zdarzeń w celu określenia potrzeby zebrania informacji od ekspertów. Analitik może zastosować

standardowe procedury (o ile zostały zdefiniowane) do określenia znaczenia ryzyka awarii komponentu lub błędu ludzkiego (Fheili 2006).

Warunkiem pozyskania wiedzy od ekspertów jest to, że należy stosować te metody głównie w odniesieniu do ryzyka istotnych zdarzeń, dla których brak dodatkowych źródeł informacji o „szkodowości”. Nie ma sensu zbieranie opinii ekspertów w każdym przypadku, ponieważ prowadzi to do znacznego przeszacowania ocen.

W tabeli poniżej przedstawione zostały dane nt. banków stosujących metody pozyskiwania wiedzy od ekspertów w podziale na typy scenariuszy.

Liczba i procent banków stosujących daną strategię zbierania scenariuszy w podziale na regiony

	Razem		Australia		Europe		Japonia		Północna Ameryka	
Liczba banków	42		5		20		7		10	
	#	%	#	%	#	%	#	%	#	%
Scenariusze ogólne dotyczące całego banku	17	40%	1	20%	7	35%	4	57%	5	50%
Dedykowane scenariusze dotyczące danej linii biznesowej	13	31%	2	40%	6	30%	2	29%	3	30%
Dedykowane scenariusze dotyczące danej pod-linii biznesowej	11	26%	2	40%	2	10%	1	14%	6	60%
Inne	5	12%	0	0%	2	10%	0	0%	3	30%

Tabela 23. Analiza scenariuszy w podziale na granularność. Źródło (BCBS 2009b)

Warto prześledzić liczbę scenariuszy wykorzystywanych w różnych bankach.

		Wszystkie regiony	Australia	Europa	Japonia	Północna Ameryka
Wszystkie podejścia						
Ogólna liczba banków		121	11	60	18	23
Liczba banków niekorzystających ze scenariuszy		56	4	28	7	8
Liczba banków wykorzystujących scenariusze		65	7	32	11	15
Banki w podziale na technikę zbierania danych						
Podejście indywidualne		34	4	13	9	8
Podejście percentylowe		18	2	15	0	1
Podejście przedziałowe		13	1	4	2	6
Liczba używanych w banku scenariuszy	mediana	115	204	95	673	71
	Zakres kwart.	(41-600)	(141-600)	(36-437)	(50-1491)	(23-215)
Panel A: podejście indywidualne						
Liczba banków korzystających ze scenariuszy		34	4	13	9	8
Liczba używanych w banku scenariuszy	mediana	108	26	56	441	29
	Zakres kwart.	(29-684)	(22-79)	(20-437)	(46-1446)	(23-301)
Maksymalna wartość scenariusza (mln €)		101 224	404	1 931	101 224	12 320
Panel B: podejście percentylowe						
Liczba banków korzystających ze scenariuszy		18		15		
Liczba używanych w banku scenariuszy	mediana	153		153		
	Zakres kwart.	(42-869)		(33-3 840)		
Liczba przedziałów percentylowych	mediana	4		4		
	Zakres kwart.	(2-4)		(2-5)		
Maksymalna wartość scenariusza (mln €) (percentyl)		1198 (99)		1 198		
Panel C: podejście przedziałowe						
Liczba banków korzystających ze scenariuszy		13		4		6
Liczba używanych w banku scenariuszy	mediana	183		158		101
	Zakres kwart.	(88-401)		(85-322)		(71-215)
Liczba przedziałów dotkliwości	mediana	6		5		6
	Zakres kwart.	(4-7)		(3-7)		(5-6)
Maksymalna wartość przedziału scenariusza (od-do) (mln €)		(506-1 110)		(10-500)		(158-316)


Tabela 24. Liczba scenariuszy używanych w bankach. Źródło (BCBS 2009a)

Przykład procesu zebrania informacji od ekspertów

Przypadek 1 - zbieranie opinii ekspertów dotyczących awarii sprzętu.

Poniżej opisany został proces na przykładzie warsztatu dotyczącego awarii sprzętu komputerowego (Gertman 2006).

Rysunek poniżej przedstawia podsumowanie kroków prowadzących do pozyskania od ekspertów wiedzy dotyczącej prawdopodobieństwa awarii sprzętu IT. Analitik departamentu ryzyka odpowiadający za spełnienie wszystkich procedur postępowania definiuje zakres ramy problemu, identyfikuje właściwych ekspertów, zwołuje zespół ekspertów, pilnuje, aby w ciągu spotkania osiągnięty został konsensus w postaci oszacowania zagregowanego stopnia awaryjności na bazie analizy ryzyka.



Rysunek 54. Schemat procesprzeprowadzenia warsztatów. Źródło: (Gertman 2006).

Przypadek 2 - zbieranie opinii ekspertów dotyczącego błędów ludzkich

Proces prowadzenia wywiadu z ekspertami w sprawach dotyczących błędów ludzkich różni się od procesu oceny „awaryjności” sprzętu tylko w kilku szczegółach (Boring 2010)

- Podczas opracowywania wyników szczególny nacisk powinien być położony na dokumentowanie wszelkich dostępnych informacji, które mogłyby pomóc w określeniu tzw. czynników kształtujących wydajność (PSF - Performance Shaping Factors). Analityk departamentu ryzyka powinien dokładnie opisać odpowiednie uwarunkowania ludzkich działań, które pomogą ekspertom w przypisywaniu poziomów PSF. Jeśli eksperci nie są zaznajomieni z metodyką kwantyfikacji tych poziomów, ważne jest, aby analityk dołączył opis odpowiedniego narzędzia
- Podczas wyboru ekspertów, ważne jest, aby wziąć pod uwagę odpowiednie czynniki ludzkie oraz kwalifikacje, które są na ogół wyższe niż kwalifikacje ekspertów oceniających awarie sprzętu.

Zakres informacji zbieranych od ekspertów

Bardzo ważne jest zapewnienie wszystkim ekspertom dostępu do tej samej informacji na temat scenariusza i upewnienie się, że wszyscy eksperci rozumieją problem. Eksperci muszą być poinformowani, w jaki sposób ich opinia będzie używana, aby starali się przedstawić najlepsze oszacowania. Poniżej przedstawiono kroki, jakie należy podjąć, aby wszyscy eksperci otrzymali te same informacje. Analityk powinien stworzyć odpowiedni dokument, w którym:

- Określi rodzaj problemu poddanego analizie. Rodzajem problem może być rzeczywista awaria sprzętu lub błędy ludzkie, ale też mogą to być potencjalne, ukryte zdarzenia, które powstaną w wyniku uszkodzenia lub błędów, gdyby nie zostały wykryte.
- Podsumuje problem. Opis problemu powinien być zwięzły skupiający się na jego znaczeniu dla ogólnego poziomu ryzyka.
- Zapewni opis kontekstu i odpowiednią dokumentację. Przedstawi odpowiednie opisy przypadków podobnych wydarzeń. Wszelkie informacje historyczne dotyczące wiarygodności podsystemów lub składników powinny być uwzględnione w odnośnym dokumencie.
- Przedstawi podsumowanie wyników wstępnej analizy, łącznie z oszacowaniem częstości możliwości wystąpienia zdarzenia. Wstępna analiza powinna obejmować nominalne lub domyślne szacunki „szkodowości” elementów, które posłużą jako podstawa, na której eksperci będą szacować wskaźnik „szkodowości” dla danego zdarzenia. Podsumowanie problemu powinno być jasne na ile to tylko możliwe, dotyczy to selekcji informacji, która ma być włączona do analizy np. analityk powinien rozważyć czy powinien położyć nacisk na uzależnienia, wspólne przyczyny itp.
- Przedstawi zwięzłą definicję informacji wymaganych od eksperta. Ekspert powinien wiedzieć dokładnie, co jest wymagane dla oszacowania parametrów zdarzenia.

6.7. Pozyskiwanie wiedzy od ekspertów

Preferowaną formą kontaktu między analitykiem departamentu ryzyka i ekspertem jest kontakt osobisty w formie warsztatów. Ta metoda jest szczególnie polecana w przypadku korzystania z ekspertów zewnętrznych. Jeśli ta forma komunikacji nie jest możliwa, trzeba rozważyć rozmowy telefoniczne lub wideo konferencję, jako alternatywny sposób kontaktu z ekspertami oraz kanału przekazywania materiałów. W ostateczności można skorzystać z pisemnej komunikacji elektronicznej, takich jak: e-maile, listy i komunikatory. Aczkolwiek trzeba pamiętać, że z wyjątkiem komunikatorów, metody te nie dają analitykowi możliwości komunikacji w czasie rzeczywistym, wprowadzając tym samym potencjalne źródło pogorszenia jakości danych (Peters 2009).

Analityk departamentu ryzyka powinien przygotować opis problemu. W tym celu powinien przedsięwziąć następujące kroki:

- Analityk powinien opisać ekspertowi problem, lub zadanie, dla którego potrzebny jest osąd eksperta poprzez podanie najistotniejszych cechy i właściwości problemu,
- Raport eksperta powinien właściwie zawierać jego nazwisko i afiliację. W niektórych przypadkach ekspert może wybrać anonimowość. Trzeba jednak zwrócić uwagę, że możliwość identyfikowania eksperta wpływa na preferowany poziom odpowiedzialności i może być wymagana dla wiarygodności analizy ryzyka.
- Ekspert powinien opisać stan jego wiedzy w kwestii problemu.
- Analityk, który prowadzi dyskusję odwołując się do zrozumienia problemu przez ekspertów, powinien racjonalnie godzić opinie ekspertów. Jeśli występują niezgodności, analityk może rozważać i analizować nowe opinie wyrażane przez ekspertów i używać ich podczas panelu ekspertów, lub może wyjaśniać skąd bierze się brak zrozumienia problemu.
- Ekspert powinien dostarczyć listę czynników i założeń, które są związane z problemem. Na przykład, ekspert może opierać się na osobistych doświadczeniach zdobytych ostatnio. Ekspert powinien również opisać ograniczenia w sprawie stosowania doświadczeń z przeszłości do bieżącej oceny problemu. Informacja ta służy do udokumentowania procesu szacowania jakościowego.
- Ekspert powinien podać szacunkowe prawdopodobieństwo „szkody” na zadanym poziomie ufności: 50% i 95% centyla. Dobrze jest również, gdy oszacowane zostaną wartości średnie i limit maksymalny. Jeśli ekspert nie jest pewien, jaki jest wskaźnik „awaryjności”, analityk powinien zadać pytania pomocnicze, aby opisać wskaźnik z punktu widzenia najgorszego przypadku i typowych scenariuszy. Dla najgorszego przypadku, ekspert powinien np. oszacować maksymalny procent czasu, w którym sprzęt może nie działać (co odpowiada 95% centylowi przypadku), a następnie dla typowego przypadku (co jest równoważne 50% centylowi).

Prawdopodobieństwo zdarzenia może być wyrażona jako prawdopodobieństwo (np. 1%, 10%), lub stosunek (np. 1/1000, 1/5). Analityk może wyjaśnić, że "najlepsze" szacunki będą wykorzystywane jako mediany. Wartość mediany może być interpretowana, jako oszacowanie, w którym ekspert

uważa, że istnieje 50% szans na to, iż "prawdziwa" wartość jest w rzeczywistości wyższa niż szacowana (analogicznie oznacza to, że jest 50% szans na to, że "prawdziwa" wartość jest niższa). Górną granicę oszacowania można traktować, jako szacunkową wartość, którą eksperci uważają, że istnieje duże prawdopodobieństwo (np. 95% szans), że "prawdziwa" wartość będzie niższa niż jego oceny (i tylko 5% szans, że "prawdziwa" wartość będzie wyższa).

Wartości te mogą zostać później wykorzystywane do estymacji rozkładu prawdopodobieństwa takiego jak np. beta dla wartości szacunku. Formy rozkładów prawdopodobieństwa zostaną przedyskutowane później. Warto zauważyć, że nie jest konieczne zbieranie dolnego 5% percentyla. Np. w przypadku szacowania czasu, w którym sprzęt może nie działać, 5% przedział ufności czasu, jest podobny do skutecznego działania sprzętu, a nie awarii sprzętu.

Należy zauważyć, że analityk departamentu ryzyka może odwrócić kolejność dokumentowania procesu i czynności szacowania prawdopodobieństwa, ale w literaturze dotyczącej pozyskiwania wiedzy od ekspertów dominuje przekonanie, że wcześniejsze „zmuszanie” eksperta do ilościowego ujęcia problemu zwiększa wagę doświadczenia historycznego, co może prowadzić do obciążeń. Czasami zaleca się przeprowadzenie treningu na danych wirtualnych lub historycznych. Doświadczenia wykazały, że treningi związane z kalibracją skali są czasochłonne (Boring 2004) i mogą powodować jedynie minimalną przewagę nad zastosowaniem 50% i 95% percentyla (O'Hagan 2004).

Po zakończeniu zbierania opinii ekspertów, analityk powinien przystąpić do oceny i weryfikacji wyników sesji. Analityk powinien dokładnie zapoznać się z opinią ekspertów i wyjaśnić wszelkie nieporozumienia i otwarte problemy zidentyfikowane w trakcie przeglądu.

Zwołanie panelu ekspertów

W przypadku zbierania informacji w postaci ankiet indywidualnych nie zawsze istnieje konieczność przeprowadzania warsztatów. Gdy wszystkie szacunki ekspertów zgadzają się z dokładnością do czynnika „3” (3 razy), nie jest konieczne zwołanie panelu ekspertów []. Analityk powinien przejść bezpośrednio do agregowania danych. Jeśli szacunki różnią się więcej niż trzykrotnie, analityk powinien zorganizować warsztat i zebrać wszystkich ekspertów w celu przedyskutowania szacunków.

Odpowiednią formą dla tego panelu są warsztaty „twarzą w twarz”, ale jest możliwe zastąpienie spotkania bezpośredniego np. telekonferencją lub wideokonferencją. Ważne jest, aby panel został zwołany w stosunkowo niedługim czasie po wykonaniu procedury zaznajomienia ekspertów z przygotowanymi materiałami dotyczącymi problemu - czyli zazwyczaj w ciągu jednego tygodnia. W dyskusji panelowej można wyróżnić dwie części:

- Pierwsza część - analityk przedstawia krótkie podsumowanie każdej z ocen ekspertów. Eksperci powinni powstrzymać się od komentowania, dopóki wszystkie streszczenia ocen nie zostaną przedstawione przez analityka. Analityk prezentuje również średnią z oszacowań w celu ułatwienia dyskusji.
- W drugiej części - analityk występuje, jako moderatora dyskusji w grupie. Celem dyskusji powinno być wyjaśnienie poszczególnych szacunków, omówienie podobieństw i różnic oraz dojście do konsensusu pomiędzy ekspertami na poziomie 50% i 95% centyla wartości prawdopodobieństwa. Dobrze jest przygotować pewien wzorzec dokumentacji, która

pozwoiłaby analitykowi na podsumowanie głównych punktów dyskusji. Opinie mogą się znacznie różnić, ale ton dyskusji, powinien pozostać neutralny, aby nie podważać ważności poszczególnych szacunków ekspertów.

Każdy ekspert powinien mieć możliwość modyfikowania swojego indywidualnego podejścia do oceny w ciągu całego panelu w celu uwzględnienia dodatkowych informacji uzyskanych w wyniku dyskusji panelowej. Przykładową agendę spotkania panelowego przedstawiono w tabeli poniżej. Czas panelu w przypadku trzech ekspertów, nie powinien przekroczyć 30 min. Nawet, jeśli istnieje rozbieżność poglądów i niemożliwe jest dojście do konsensusu, analityk powinien zamknąć panel w uzgodnionym terminie.

Przykładowa agenda panelu dyskusyjnego:

<i>Prowadzący</i>	<i>Czas</i>	<i>Temat</i>
<i>Analityk</i>	<i>15 min</i>	<i>Wprowadzenie do tematu</i>
<i>Analityk</i>	<i>5 min per ekspert</i>	<i>Podsumowanie wstępnych oszacowań dokonanych przez ekspertów - prezentacje</i>
<i>Eksperci</i>	<i>15 min</i>	<i>Pytania i dyskusja mająca na celu omówienie wstępnych oszacowań</i>
<i>Eksperci</i>	<i>20 min</i>	<i>Dyskusja o problemie i dodatkowe uwagi np. nowe oszacowania</i>
<i>Eksperci</i>	<i>10 min</i>	<i>Wypracowanie końcowego konsensusu</i>
<i>Analityk</i>	<i>10 min</i>	<i>Podsumowanie dyskusji i spisanie wniosków</i>

Tabela 25. Przykładowa agenda panelu. Źródło opracowanie własne.

W wyniku panelu dyskusyjnego, prawdopodobne są dwa wyniki:

- Eksperci osiągnąć rozsądny konsensus w sprawie 50% i 95% centyla stopnia „szkodowości”.
- Nie ma zgody pomiędzy ekspertami, a tylko częściowe porozumienie lub nie ma konsensusu na 50% i 95% centyl stopnia „szkodowości”.

W obu przypadkach opinie przeciwne powinny być odnotowane w dokumencie podsumowującym. Gdy istnieje konsensus tzn. rozbieżności są mniejsze niż czynnik trzykrotny, średnia z tych wartości może być stosowana z dalszego uzgadniania. Gdy zgodność jest mniej doskonała często konieczne jest stosowanie matematycznych modeli agregacji indywidualnych szacunków ekspertów.

Agregacja wyników

Prosta technika łączenia polega na policzeniu wartości oczekiwanej wyników podanych przez ekspertów dla: mediany i górnej granicy czyli 95% centyla współczynnika „szkodowości”. Wartość oczekiwaną E oblicza się, jako średnią arytmetyczną wartości dla poszczególnych ekspertów.

$$E = \frac{\sum_{i=1}^N x_i}{N}$$

gdzie x_i reprezentuje wartości mediany lub górnej granicy podane przez eksperta, a N oznacza liczbę ekspertów. Średnia arytmetyczna daje nieco bardziej konserwatywne wartości oczekiwanej

awaryjności niż średnia geometryczna (z definicji, średnia geometryczna jest równa lub mniejsza od średniej arytmetycznej). Analityk może wykorzystać średnią geometryczną, gdy istnieją ważne powody lub preferencje, aby to zrobić. Takie wykorzystanie średniej geometrycznej zamiast średniej arytmetycznej powinno być odnotowane w arkuszu agregacji. Wartość oczekiwana jest obliczana zarówno dla mediany i górnej granicy.

Obliczanie rozkładu - wprowadzanie do modelu ryzyka

Do modelowania proporcji najczęściej wykorzystuje się rozkład Beta, rozkład lognormalny lub rozkład wielomianowy. Rozkład beta przyjmowany jest w przypadku jedno-modalnym, który zazwyczaj dominuje. Przyjmuje się, że dane wejściowe dotyczące proporcji w modelu ryzyka podlegają temu rozkładowi, jest on zgodny z wymaganiami, aby stopień „szkodowości” zawierał się w granicach 0 – 1. Rozkład beta zapewnia dużą elastyczność – może być wykorzystywany, jako rozsądne przybliżenie różnych rozkładów. Jest często używany w analizie ryzyka niepewności, jako model prawdopodobieństwa wystąpienia zjawiska.

Rozkład Beta jest rozkładem dwu-parametrycznym i wymaga oszacowania dwóch parametrów, α i β . Parametry te mogą być łatwo obliczone na podstawie 50% i 95% centyla wartości wyniku otrzymanego z uzgodnionej wartości podawanej przez ekspertów lub w wyniku agregacji.

Ponieważ nie ma analitycznej formy do obliczenia, α i β , wartości są uzyskane za pomocą programów optymalizacji nieliniowej.

Innym rozkładem używanym przy obliczaniu proporcji jest rozkład wielomianowy. Rozkład wielomianowy jest uogólnieniem rozkładu dwumianowego, gdzie mamy k możliwych stanów, w które są realizowane w n doświadczeniach.

Wzór na prawdopodobieństwo w rozkładzie wielomianowy względem ilości realizacji poszczególnych stanów dany jest wzorem:

$$W_{(k_1, k_2, \dots, k_m)}^n = \frac{n!}{\prod_{j=1}^m k_j!} \prod_{j=1}^m p_j^{k_j}$$

gdzie:

- k_i - liczba realizacji stanu i
- p_i - prawdopodobieństwo realizacji stanu i

Rozkład wielomianowy wykorzystywany jest w modelach multiplikatywnych, jest bardzo dobrym rozszerzeniem rozkładu Bernoulliego.

Należy pamiętać, że niektórzy analitycy wolą szacować stopień „szkodowości” za pomocą rozkładu log-normalnego. Jest on równie powszechnie stosowany i zrozumiały. Rozkład log-normalny wymaga obliczenia dwóch parametrów μ oraz σ . Jest to o tyle łatwe, że istnieje forma analityczna

$$\text{Mediana} = e^{\mu}$$

$$\text{Średnia} = e^{\mu + \sigma^2/2}$$

Należy pamiętać, aby zachować ostrożność i nie przekroczyć górnej granicy $=1$. Analityk powinien rozważyć użycie transformacji logistycznej lub innej (log-log, cum-log-log itp.) w celu ograniczenia wartości estymatorów do przedziału $[0,1]$. Inne rozkłady też są możliwe do stosowania choć są stosowane znacznie rzadziej.

7. Kwantyfikacja eksperckich - metoda Duration

7.1. Wstęp

W tym rozdziale wprowadzona zostanie nowa metoda kwantyfikacji opinii eksperckich – metoda „casu trwania –duration.

Analizy scenariuszowe służą do wyliczenia wartości ryzyka. W praktyce, sprowadza się to do wyboru, na podstawie scenariuszy:

- odpowiedniego rozkładu parametrycznego,
- estymacji jego parametrów,
- wyznaczenie percentyla odpowiadającego ryzyku.

Bardzo często wybór rozkładu dokonywany jest na podstawie histogramów uzyskanych ze scenariuszy eksperckich, które następnie przybliżane są przez rozkład parametryczny.

(Frachot 2001) zwrócił uwagę na inną możliwość wykorzystania scenariuszy. Mogą one służyć do definiowania ograniczeń parametrów poszukiwanego rozkładu w ramach zadanej rodziny rozkładów. Gdy ograniczenia zostaną ustalone, można zastosować strategię największej wiarygodności, przy pomocy, której szacuje się parametry dotyczące rozkładów częstotliwości i dotkliwości. Metoda ta zwana metodą „czasu trwania” lub duration powoli zdobywa miejsce w praktyce bankowej (BCBS 2009a). Z punktu widzenia matematycznego, metoda duration jest bardzo atrakcyjna i może stać się w najbliższej przyszłości dominującą metodą kwantyfikacji opinii eksperckich.

7.2. Metoda Duration

Filozofię metody duration opisać przy pomocy następującego przykładu. Eksperti budują n scenariuszy [Steinhoff i Baule (2006)]. Każdy scenariusz można sprowadzić do ustalenia progu straty x oraz oszacowania czasu D który upłynie do pojawienia się straty powyżej progu. W ten sposób wyniki scenariuszy można przedstawić w postaci par (x, D) .

Założmy, że częstotliwość zdarzeń może być opisana rozkładem Poissona z parametrem λ . Każdy ekspert ocenia parametr wg swojego rozeznania, otrzymujemy więc n parametrów λ_i , gdzie $i = 1, 2, \dots, n$. W przypadku kwantyfikacji prognoz eksperckich założenie dotyczące rozkładu Poissona nie wydaje się założeniem mocnym. Rozkład Poissona ma kilka atrakcyjnych właściwości. Przypomnijmy, że λ_i w rozkładzie Poissona oznacza średnią roczną liczbę strat, szacowaną przez i -tego eksperta. Niech F_i oznacza funkcję rozkładu dotkliwości opisującą modelowane ryzyko operacyjne i będzie elementem k -parametrycznej rodziny F (np. 2-parametrycznej rodziny log-normalnej) .

Niech progi będą uporządkowane od najmniejszego do największego - najlepszym scenariuszem i -tego eksperta jest scenariusz 1 o najniższym progu x_{i1} , a najgorszy scenariusz ma najwyższy próg x_{in} . Prawdopodobieństwo zaobserwowania strat większych niż najgorszy scenariusz dane jest przez:

$$Pr(X > x_{in}) = 1 - Pr(X \leq x_{in}) = 1 - F_i(x_{in}; \theta_{i1}, \theta_{i2}, \dots, \theta_{ik})$$

gdzie $\psi_{i1}, \dots, \psi_{ik}$ są parametrami rozkładu dotkliwości odpowiadającymi ocenie eksperta i. Muszą być oszacowane w oparciu o opinię tego eksperta. Jeśli opinie ekspertów są modelowane przez rozkład log-normalny szacowane parametry mogą być równe odpowiednio: $\hat{\theta}_{i1} = \hat{\mu}_i$ oraz $\hat{\theta}_{i2} = \hat{\sigma}_i$.

Średnia roczna liczba strat większych niż x_{in} jest równa:

$$\lambda_i(1 - F_i(x_{in}; \theta_{i1}, \theta_{i2}, \dots, \theta_{ik}))$$

Obliczenie wartości oczekiwanej duration

Bardziej formalnie metodę duration można wprowadzić w następujący sposób.

Do modelowania częstości zdarzeń użyjemy proces stochastyczny zliczający. Proces $\{N_t\}_{t \geq 0}$ nazywamy zliczającym, gdy N_t jest równe całkowitej ilości zdarzeń w przedziale czasu $(0, t)$. Dodatkowo często się zdarza, że liczby zdarzeń w dwóch rozłącznych przedziałach czasowych są niezależnymi zmiennymi losowymi. Proces taki nie ma pamięci - wcześniejsze realizacje procesu nie wpływają na prawdopodobieństwo zajścia zdarzenia w danym czasie

Własność tę określa się jako proces Poissona.

Definicja: proces zliczający nazywa się procesem Poissona z intensywnością λ gdy:

1. $N_0 = 0$
2. Ma niezależne i stacjonarne przyrosty
3. Liczba zdarzeń w przedziale $(0, t)$ ma rozkład Poissona z parametrem λt

$$Pr(N_{t+s} - N_s = k) = e^{-\lambda t} \frac{(\lambda t)^k}{k!}$$

Związek pomiędzy procesami Poissona a modelami zdarzeń opiera się na poniższym twierdzeniu:

Twierdzenie: Proces zliczający, pojedynczy o stacjonarnych, niezależnych przyrostach jest procesem Poissona.

Do modelowania częstości zdarzeń ocenianych w procesie samooceny będziemy używali procesu Poissona.

Niech dany będzie proces Poissona $\{N_t\}_{t \geq 0}$ oraz niech T_1 będzie czasem pierwszego zdarzenia, T_2 czasem drugiego zdarzenia itd. Wówczas ciąg $\{T_i\}_{i \geq 1}$ będzie ciągiem czasów pomiędzy zdarzeniami. Jak łatwo zauważyć $\{T_1 > t\} = \{N_t = 0\}$ czyli

$$Pr(T_1 > t) = e^{-\lambda t}$$

Dalej mamy dla $T_1 = s$ (gdzie $t > s$) pod warunkiem, że zdarzenia są niezależne

$$Pr(T_2 > t) = E(Pr(T_2 > t | T_1 = s)) = e^{-\lambda(t-s)}$$

Mamy więc wynik: ciąg czasów $\{T_i\}_{i \geq 1}$ pomiędzy niezależnymi zdarzeniami jest zmienną losową o rozkładzie wykładniczym ze średnią $\frac{1}{\lambda}$.

Oznaczmy dalej przez S_k czas pomiędzy k-tymi zdarzeniami wówczas:

$$S_k = \sum_{i=1}^k T_i$$

Rozkład zmiennej losowej S_k ma postać Erlanga z parametrami (k, λ) , gdzie f-cje rozkładu

$$f_{k,\lambda}(t) = \lambda e^{-\lambda t} \frac{(\lambda t)^{k-1}}{(k-1)!}$$

$$F_{k,\lambda}(t) = \begin{cases} 1 - \sum_{i=0}^{k-1} \left(\frac{(\lambda t)^i}{i!} \right) e^{-\lambda t} & t \geq 0 \\ 0 & t < 0 \end{cases}$$

Możemy teraz zbudować model dla naszego procesu samooceny (RCSA).

Jeżeli założymy, że zdarzenia operacyjne x_t są niezależne i stacjonarne rozkład wartości możemy opisać rozkładem dotkliwości $F_\theta(x)$ (w skrócie $F(x)$), a do modelowania dynamiki czyli możemy użyć procesu Poissona o nieznanej intensywności λ , wówczas czas (e_k) upływający pomiędzy dowolnymi k-tymi zdarzeniami $(T_{i+k} - T_i)$ o wartościach przekraczających X .

Niech liczba zdarzeń prowadzących do strat jest opisywana procesem Poissona o intensywności λ (Frachot 2003). Niech t_i oznacza czas zajścia i-tego zdarzenia. Wówczas $d_i = t_i - t_{i-1}$ jest czasem upływającym między dwoma kolejnymi zdarzeniami. Czasy d_i są niezależne i mają rozkład wykładniczy z parametrem λ . Zakładamy, że straty X są niezależne oraz mają jednakowy rozkład F .

Policzmy rozkład d_i - czasu między dwoma zdarzeniami, dla których wartość straty przekroczyła próg x_0 . Czasy trwania są w dalszym ciągu niezależne i mają jednakowy rozkład, wystarczy więc policzyć rozkład dla d_1 :

$$\begin{aligned} Pr(d_1 > t) &= \sum_{i \geq 1} Pr(t_i > t; x_1 < x_0, \dots, x_1 < x_0, x_i \geq x_0) \\ &= \sum_{i \geq 1} Pr(t_i > t) F(x)^{i-1} (1 - F(x)) \\ &= \sum_{i \geq 1} F(x)^{i-1} (1 - F(x)) \sum_{k=0}^{i-1} e^{-\lambda t} \frac{(\lambda t)^k}{k!} \\ &= (1 - F(x)) \sum_{k=0}^{\infty} e^{-\lambda t} \frac{(\lambda t)^k}{k!} \sum_{i=k}^{\infty} F(x)^i \\ &= e^{-\lambda t} \sum_{k=0}^{\infty} \frac{(\lambda t)^k}{k!} F(x)^k = e^{-\lambda(1-F(x))t} \end{aligned}$$

Rozkład czasu pomiędzy dwoma kolejnymi zdarzeniami redukuje się do rozkładu wykładniczego:

$$Pr(d_1 > t) = e^{-\lambda(1-F(X))t}$$

Stąd średni czas oczekiwania pomiędzy dwoma kolejnymi stratami przekraczającymi wartość x_{in} jest równy:

$$E(e_i) = \frac{1}{\lambda_i(1 - F_i(x_{in}; \theta_{i1}, \theta_{i2}, \dots, \theta_{ik}))}$$

7.3. Metody kwantyfikacji i agregowania wiedzy eksperckiej – łączenie opinii ekspertów

W wielu zadaniach, gdzie problemem jest dostęp do odpowiednich danych historycznych, np. zdarzenia są rzadkie lub wręcz nie istnieją (np. w przemyśle atomowym, sejsmologii, itp.), sięga się do opinii ekspertów (Hukki 2008). Zazwyczaj bierze się pod uwagę, opinię więcej niż jednego eksperta. Innymi słowy, model decyzyjny opiera się na „uśrednieniu” opinii zebranych od kilku ekspertów. Opinia każdego eksperta reprezentowana jest w tym modelu poprzez ocenę nieznanego parametru rozkładu θ . W ryzyku operacyjnym, θ jest parametrem rozkładu prawdopodobieństwa dotkliwości strat. Problemem, który należy rozwiązać, jest połączenie kilku prawdopodobieństw reprezentujących szacunki poszczególnych ekspertów w jedno oszacowanie prawdopodobieństwa, które powinno być stosowane zgodnie z metodologią LDA (Agostini 2010).

Uzgodnienie wartości parametru θ może być dokonane w tzw. procesie grupowym to znaczy konsensus następuje podczas dyskusji – jako wynik uzyskujemy jedną opinię. W tym przypadku ma zastosowanie podejście behawioralne w sensie próby wygenerowania porozumienia między ekspertami poprzez ich interakcję (Clemen 1999), które nie opiera się na aksjomatach prawdopodobieństwa i dlatego w tym przypadku nie buduje się modelu matematycznego „uśredniania” opinii.

Problem można próbować rozwiązać, powołując się na aksjomaty rachunku prawdopodobieństwa. Jedną z metod rozwiązania problemu jest tzw. liniowa przestrzeń opinii. Matematycznie można to wyrazić w poniższy sposób.

Weźmiemy pod uwagę k ekspertów oraz liniowy system wag w postaci:

$$Pr = \sum_{i=1}^k w_i P_i$$

gdzie Pr – poszukiwane prawdopodobieństwo

P_i – opinia i -tego eksperta

w_i - waga i -tego eksperta, wagi powinny spełniać warunek normalizacji $\sum_{i=1}^k w_i = 1$

Najprostszym rozwiązaniem jest średnia opinia, to znaczy przyjęcie $w_i = 1/k$ dla wszystkich i . Jeżeli jednak istnieją różnice pomiędzy ekspertami powinien zostać ustalony pewien ranking na podstawie wskaźników mierzących "dobroć" lub "niezawodność" każdego eksperta. Lista rankingowa może być

utworzona przez menedżera na podstawie jego subiektywnej oceny. Niestety, w tym przypadku główna zaleta tej metody, jaką jest prostota, jest jednocześnie jej wadą.

Zadając pytania odnośnie kwantyfikacji rozkładów prawdopodobieństwa musimy mieć na uwadze funkcje biznesowe, a mianowicie metody ilościowe muszą być dostosowane do warunków takich jak:

- Warunek # 1. Końcowa ocena powinna rzeczywiście łączyć opinie ekspertów na temat parametrów θ niezależnie od przykładowego scenariusza użytego w trakcie warsztatów.
- Warunek # 2. Ocena powinna być akceptowana przez kierownika odpowiedniej linii biznesowej, który ponosi ostateczną odpowiedzialność za proces.
- Warunek # 3. Powinna opierać się na obiektywnych metodach, które mogą być uznane przez nadzór.
- Warunek # 4. Uzyskany wynik powinien być koherentny z innymi wynikami w ramach metodologii LDA.

Warunki # 1 i # 4 są spełnione w przypadku równych wag, przy podejściu rankingowym mamy jednak kłopot z warunkiem # 3. Dlatego bardziej przekonującym sposobem jest oparcie rankingu na mierze dokładności z poprzednich ocen dokonanych przez ekspertów. Można to zrobić przy użyciu klasycznego modelu (Cooke 1991), testując poziom specjalizacji każdego eksperta za pomocą kwestionariusza zawierającego pytania związane bezpośrednio z oceną parametru θ (pytania docelowe), a także pytania, na które osoba oceniająca (w naszym przypadku analityk Decision Maker - DM) zna odpowiedzi (pytania naprowadzające). Oceny odpowiedzi na te pytania mogą być następnie wykorzystywane do oceny każdego eksperta poprzez karty punktowe (system scoringowy). W dziedzinie ryzyka operacyjnego, metoda ta została zastosowana u Bakker (2004).

Czasami proponowane są alternatywne metody nieliniowe np. logarytmiczny zbiór opinii. Zaawansowane liniowe rozwiązania, takie jak klasyczny model (Cooke 1991) czy logarytmiczna przestrzeń opinii, spełniają warunek # 3, ale często nie zapewniają satysfakcjonującej odpowiedzi na warunek # 2.

(Clemen 1999) klasyfikują metody pozyskiwania i agregacji ocen ekspertów w dwóch wymiarach: matematycznym i behawioralnym. W modelach matematycznych, poszczególne oceny ekspertów, z uwagi na niepewność, są wyrażane, jako subiektywne prawdopodobieństwa. Następnie, są łączone za pomocą różnych metod matematycznych. W modelach behawioralnych główny nacisk kładzie się na osiągnięcie pewnego rodzaju konsensusu wśród grupy ekspertów, którzy zazwyczaj są zachęcani do działań interakcyjnych i dzieleniem się swoją oceną. Wyniki uzyskane tą metodą nie muszą spełniać aksjomatów rachunku prawdopodobieństwa.

Powszechnie uważa się, że przy agregowaniu wiedzy eksperckiej matematyczne podejście daje dokładniejsze wyniki niż metody behawioralne (Clemen 1989).

Modele behawioralne

Jedną z bardziej znanych metod behawioralnych jest technika Delphi. W metodzie tej, podczas panelu eksperci proszeni są o anonimowe oceny opinii innych ekspertów. Każdy z ekspertów ma szansę na ponowne przeprowadzenie oceny swojego pierwotnego szacowania na podstawie

przeglądu innych ocen. Zwykle proces ten jest powtarzany w cyklu kilku rund aż uzyska się zadowalające zmniejszenie rozrzutu opinii (Cooke 1991).

Inną metodą jest Metoda Grup Nominalnych (MGN). MGN to metoda behawioralna, w której eksperci w celu osiągnięcia konsensusu mogą przedyskutować swoje szacunki między sobą, w kontrolowanym środowisku (Delbecq et al. 1975). Metoda MGN może pomóc zidentyfikować błędy i obciążenia opinii ekspertów już w trakcie procesu kwantyfikacji. Nie istnieją niestety, żadne formalne przepisy, które pozwoliłyby automatycznie godzić różnice, kiedy konsensus jest trudny do osiągnięcia. Zgodność osiągnięta przez interakcyjne oddziaływanie w grupie jest główną zaletą tej metody. Mosleh et al. (1988) zwraca uwagę, że interakcyjny proces też nie jest odporny na różnego rodzaju obciążenia, na przykład tendencję do ograniczania udziału ekspertów mniej pewnych siebie, a wprowadzenie nadreprezentatywności dominujących osobowości czy też chęć osiągnięcia szybkich wniosków. Genest i Zidek (1986) ostrzegają przed potencjalnym wpływem zachowań określanych jako: manipulacja strategiczna, blefowanie, zastraszanie itp., co często ma miejsce w trakcie dialogu. (Cooke 1991) wskazuje, że interakcja w grupie tworzy tendencję do faworyzowania ekstremalnych szacunków prawdopodobieństwa. Zagadnienia dotyczące polaryzacji grupowej są omawiane przez (Garthwaite 2005). Istnieje szeroka literatura omawiająca metody szacowania konsensusu w grupie (Fumika 2004) (Hickey 2003).

Szeroką klasę modeli behawioralnych stanowią psychologiczne modele skalowania. Podejście to pochodzi z badań intensywności szacowania fizycznych bodźców, które rozwinęły się na bazie oceny symulowanych scenariuszy relatywnych intensywności. Zakłada ono, że każdy ekspert ma jakieś wewnętrzne preferencje odnośnie badanego zjawiska związane ze swoimi zainteresowaniami i wiedzą i może dostarczyć je w postaci oceny, niekoniecznie w formie liczbowej. Analityk DM (Decision Maker) prowadzący warsztaty prosi ekspertów o podanie swoich preferencji odnośnie porównań częstości dla poszczególnych par zdarzeń będących często scenariuszami jakichś symulacji. Oceny ekspertów można mierzyć w formie oceny przedziałowej z zadanymi granicami ufności przy użyciu modeli statystycznych np. często używanym rozwiązaniem jest model Bradley-Terry.

Założmy, że mamy n ekspertów, każdy ekspert analizuje pary zdarzeń i jest proszony o wyrażenie swoich preferencji odnośnie częstotliwości zajścia jednego z nich. Niech $A_1, \dots, A_k$ będą porównywanymi zdarzeniami, a $(p_1, \dots, p_k)$ oznaczają rzeczywiste prawdopodobieństwa tych zdarzeń. Niech $V(i, e)$ oznacza wewnętrzną wartość eksperta e dla zdarzenia i . Wartości te powinny zachowywać uporządkowanie zbioru zdarzeń odnośnie prawdopodobieństwa wystąpienia, co oznacza, że ekspert e preferuje zdarzenia A_i o większym prawdopodobieństwie w porównaniu do zdarzenia A_j . Inaczej mówiąc, jeżeli $\text{pr}(A_i) \geq \text{pr}(A_j)$ wówczas $V(i, e) \geq V(j, e)$.

W modelu B-T zakłada się, że każde zdarzenie A_i jest związane z prawdziwym prawdopodobieństwem wystąpienia poprzez wartości $V(i, e)$. Prawdopodobieństwo, że zdarzenie A_i będzie preferowane w stosunku do zdarzenia A_j , oznaczmy przez r_{ij} wówczas miarę tej preferencji można zdefiniować przez:

$$r_{ij} = E_e \left[\frac{V(i, e)}{V(i, e) + V(j, e)} \right]$$

gdzie $E_e[.]$ jest wartością oczekiwaną w przestrzeni ekspertów.

Opinie ekspertów odnośnie preferencji traktowane są jako zdarzenia losowe. Proporcje ekspertów preferujących A_i w stosunku do A_j można użyć jako oszacowanie $\hat{r}_{i,j}$. Wartości estymatorów $\hat{V}(i, e)$ można obliczyć metodą największej wiarygodności przy użyciu modeli regresyjnych GLMM – (Generalized Linear Mixed Models).

7.4. Modele matematyczne

W tej części omówione zostaną modele matematyczne łączenia ekspertyz: model aksjomatyczny i model bayesowski.

Racjonalny konsensus – model aksjomatyczny

Wczesne prace nad agregacją prawdopodobieństwa koncentrowały się na znalezieniu formuły agregacji (Giudici 2007). W badaniach tych, przypisywano wstępnie pewne właściwości zagregowanemu prawdopodobieństwu, a następnie poszukiwano funkcjonalnej formuły łącznego rozkładu, który posiadałby odpowiednie własności. Dopiero sformułowanie zasady racjonalnego konsensusu pozwoliło zbudować podstawy matematyczne do modelu aksjomatycznego (Kuncheva 2004).

Racjonalny konsensus używany jest do określenia procesu podejmowania decyzji grupowej podczas panelu. Polega on na uzgodnieniu metody reprezentacji opinii w warunkach niepewności, która zapewniłaby osiągnięcie celów panelu, a jednocześnie w maksymalny sposób ograniczyła możliwe obciążenia wyników. Nie jest wymagane, aby każdy uczestnik panelu dostosował swoje zdanie do opinii innych uczestników. Bardziej chodzi o formę zgody, co do rozkładu prawdopodobieństwa rządzącego badanym zdarzeniem. Bedford i Cooke (1996) wprowadzili podstawy matematyczne formalizujące konsensus.

Ogólne zasady procesu można streścić w poniższy sposób.

Założmy, że mamy zbiór ekspertów $\{1, \dots, e\}$, niech $P^e = (P_1, \dots, P_e \mid P_i \in P)$ będzie zbiorem miar prawdopodobieństwa charakteryzujących ekspertów na określonej przestrzeni probabilistycznej. Wówczas prawo składania prawdopodobieństw powinno być funkcją $G: P^e \rightarrow P$ czyli $G(P_1, \dots, P_e) = p$.

Zakładamy, że przestrzeń probabilistyczna jest skończona i składa się ze zdarzeń $\{A_1, \dots, A_n\}$, niech dalej p_{ij} oznacza prawdopodobieństwo przypisane przez eksperta i do zdarzenia A_j . Wektor prawdopodobieństw przypisanych ekspertowi i możemy zapisać jako $P_i = (p_{i1}, \dots, p_{in})$ gdzie $p_{ij} \geq 0$ oraz $\sum_j p_{ij} = 1$. Funkcja $G()$ musi spełniać pewne warunki.:

Właściwość mocnej dostateczności: dla każdego podzbioru $A \subseteq \{A_1, \dots, A_n\}$ prawdopodobieństwo decyzji dotyczącej do A zależy tylko od orzeczeń ekspertów tzn. jeżeli $Q_i = 1 - P_i(A)$ wówczas $G(P_1, \dots, P_e)(A) = G(Q_1, \dots, Q_e)(A)$;

Właściwość zupełności brzegowej: prawdopodobieństwa nie zależą od sposobu grupowania zdarzeń;

Właściwość zachowania niezależności: jeżeli $P(A \cap B) = P(A)P(B)$ to $G(P_1, \dots, P_e)(A \cap B) = G(P_1, \dots, P_e)(A)G(P_1, \dots, P_e)(B)$.

Dodatkowy wymóg stawiany przed procesem dotyczy tzw. empirycznej kontroli. Problem może być poddany ocenie ekspertów jedynie wówczas, gdy istnieje odpowiednie doświadczenie historyczne. Oznacza to, że istnieją dane historyczne i pomiary dotyczące badanych zdarzeń, choć konkretne wielkości nie mogą być mierzone w praktyce przynajmniej w czasie podejmowania decyzji. Istnieją jednak zdarzenia historyczne, które mają na tyle dokładny opis, że można użyć ich do porównania opinii ekspertów z wynikami obserwowanymi. Pytania dotyczące takich zdarzeń mogą być wykorzystane do realizacji empirycznej kontroli. Są one zwykle określane, jako zmienne bazowe. Zmienne bazowe służą do kilku celów:

- do oszacowania dokładności opinii ekspertów, poprzez porównanie subiektywnego prawdopodobieństwa z „twardymi” danymi;
- umożliwienie łączenia rozkładów ekspertów;
- ocenę połączonych opinii ekspertów.

Zakładamy, że niepewność jest reprezentowana, jako prawdopodobieństwo subiektywne, ale wyniki dotyczą realnych zdarzeń, które mogą wystąpić. Opinia eksperta powinna być wyrażona w postaci ilościowej tak, aby mogła być uznana za dane w ten sam sposób jak dane empiryczne - obie wielkości stanowią wyraz przekonania co do określonej wartości zdarzenia, ponieważ obie zawierają element niepewności. Innymi słowy, opinia biegłego ma cechy wspólne z empirycznymi danymi z obserwacji historycznych.

Powyżej omówione założenia zostały zaimplementowane w systemie pozyskiwania wiedzy eksperckiej w ramach tzw. modelu klasycznego. Bazuje on na średniej ważonej opinii ekspertów. Wagi są określane na podstawie procedury kalibracji ekspertów mierzonych przy użyciu zmiennych bazowych. Nazwa "klasyczny model" wywodzi się z analogii pomiaru kalibracyjnego ekspertów i klasycznej strategii testowania hipotez statystycznych.

Powyższe podejście do agregacji rozkładów prawdopodobieństwa (zdefiniowane przez Stone (1961)) zrealizowane zostało w modelu zwanym **liniową przestrzenią opinii**. Decyzje dotyczące kwantyfikacji zdarzeń zależą w tym modelu od opiniach ekspertów. Przestrzeń opinii jest metodą łączenia wielu różnych opinii na temat jakiegoś nieznanego ilościowego wydarzenia A w celu zbudowania pojedynczej, „syntetycznej” opinii.

Założmy, że mamy n ekspertów i niech $p_i(A)$ reprezentuje rozkład prawdopodobieństwa podany przez eksperta i odnośnie nieznanego zdarzenia ilościowego A , $i = 1, \dots, n$ oraz niech w_i będzie wagą eksperta. Wtedy, łączny rozkład prawdopodobieństwa $p(A)$ jest ważoną kombinacją liniową prawdopodobieństw ekspertów (ważoną arytmetyczną)

$$p(A) = \sum_{i=1}^n w_i p_i(A)$$

gdzie:

- n jest liczbą ekspertów,
- $p_i(A)$ reprezentuje rozkład szacowany przez eksperta i dla pewnej nieznannej wielkości A ,
- w_i to waga i -tego eksperta.

Dla uproszczenia będziemy zakładać, że p reprezentuje dyskretną funkcję gęstości prawdopodobieństwa (w przypadku ciągłym występują pewne problemy techniczne, ale zasadniczo idea jest taka sama).

Liniowa przestrzeń opinii jest miarą reprezentującą ważoną, liniową kombinacją prawdopodobieństwa ekspertów i jako taka jest łatwa do zrozumienia, i nie wymaga specjalnych nakładów obliczeniowych. Co więcej, spełnia szereg aksjomatów (omówionych poniżej) stawianych przed tego typu miarami.

Na szczególną uwagę, zasługuje fakt, że jest ona jedyną miarą, która spełnia tzw. własność marginalizacji (WM). Załóżmy, że P jest wektorem prawdopodobieństwa pewnej wielkości, a analityk DM (Decision Maker) jest zainteresowany jednym z elementów tego wektora: P_j - czyli rozkładem brzegowym. Według WM powinniśmy uzyskać taki sam wynik niezależnie od tego czy najpierw określimy rozkłady brzegowe P_j i następnie połączymy je w łączny rozkład prawdopodobieństwa, czy też najpierw wybierzemy wspólny rozkład wektora P , a następnie obliczymy brzegowe prawdopodobieństwa P_j .

Wagi w_i wykorzystywane są do reprezentowania „jakości” różnych ekspertów, lub źródeł informacji. W najprostszym przypadku, eksperci są traktowani, jako równoważni, co prowadzi do zwykłej średniej arytmetycznej. Jeśli niektórzy eksperci są postrzegani, jako "lepsi" od innych, w tym sensie, że są bardziej precyzyjni, lub posiadają lepszą informację, można ten fakt wprowadzić do reguły decyzyjnej poprzez te wagi. W niektórych przypadkach dopuszcza się ujemne wagi. Określenie wag jest kwestią subiektywną, toteż wagom nadawane są różne interpretacje (Genest i McConway, 1990).

Innym alternatywnym podejściem do łączenia rozkładów ekspertów jest wykorzystanie średniej geometrycznej. W tym przypadku łączny rozkład prawdopodobieństwa ma postać

$$p(A) = \ell \prod_{i=1}^n p_i(A)^{w_i}$$

gdzie ℓ jest stałą normalizacyjną taką, aby wagi w_i sumowały się do jedności, co zapewnia, że $p(A)$ jest rozkładem prawdopodobieństwa. Jeśli wagi są równe ($1/n$), to łączny rozkład jest proporcjonalny do średniej geometrycznej poszczególnych rozkładów. Model ten nazywa się **logarytmiczną przestrzenią opinii**.

Logarytmiczna przestrzeń opinii spełnia warunek analogiczny do WM w przypadku liniowym, a mianowicie zasadę Zewnętrznej Właściwości Bayesa (External Bayesianity EB). Załóżmy, że DM skonsultował się z ekspertami i obliczył $p(A)$, później jednak dowiedział się kilku nowych informacji istotnych dla oceny A . W tej sytuacji może wybrać jedną z dwóch opcji. Po pierwsze: wykorzystać informację do korekty oszacowania poszczególnych rozkładów prawdopodobieństwa $p_i(A)$, a następnie połączyć je, lub wykorzystać informację do bezpośredniej aktualizacji łącznego rozkładu $p(A)$. Jeżeli w obu przypadkach wynik jest taki sam to mówimy, że formuła spełnia warunek EB.

Klasyczna metoda (Cooke 1991) opierała się na modelu liniowej przestrzeni opinii i była bardzo często stosowana do oceny ryzyka, począwszy od lat 80-tych. W celu określenia wag, w metodzie Cooke'a wykorzystuje się oceny prawdopodobieństwa dokonane przez ekspertów na zdarzeniach, dla których analityk DM zna niezależny wynik. Ocena eksperta jest empirycznie skalibrowana, jeśli

skorygowana poprzez wagę ocena wydarzenia A, dla których ekspert e ocenia szansę wystąpienia równą $\Pr(A,e)$, okazuje się faktycznie zgodna z $\Pr(A)$. Waga eksperta w liniowej przestrzeni opinii opiera się na pomiarze zgodności kalibracji, jeśli ekspert jest bardzo daleki od rzeczywistości przypisuje mu się zerową wagę.

Problem z przestrzeniami opinii generalnie sprowadza się do określenia optymalnych wag w_i dla poszczególnych ekspertów. Różne metody znalezienia optymalnych modeli były badane, np. w DeGroot i Mortera (1991), Bordley (1982), a DeGroot (1974). Najprostszym wyborem wag jest przypisanie wszystkim ekspertom równych wag $w_i = \frac{1}{n}$. Proste arytmetyczne uśrednianie ocen eksperckich jest używane w wielu badaniach (Noortwijk 1992). Cook (1991) omawia pewne kompensacje tak uproszczonej metody poprzez poprawkę procedury dla pozyskiwania wiedzy, ale jego metoda nie jest optymalna ze względu na brak jakichkolwiek prób oceny jakości szacunków ekspertów.

Trudności z aksjomatycznym podejściem są omawiana przez French (1985) i Genest i Zidek (1986). Lindley (1985) podaje przykład niepowodzenia obu aksjomatów, w prostym przykładzie pokazując, że WM ignoruje ważne informacje, a EB wymusza brak zmian w funkcji łączenia (poolingu). Ponadto, Franche (1985) podkreśla, że zasada łączenia (zdań ekspertów) nie może zaspokoić jednocześnie szeregu postulatów pożądanых z punktu widzenia interpretacji wyników. Zasada łączenia może również wpływać na cechy prawdopodobieństwa, na przykład Hora (2004) pokazuje, że połączenie dobrze skalibrowanych rozkładów prawdopodobieństwa może doprowadzić do sytuacji, w której łączny rozkład nie jest dobrze skalibrowany.

Model Cooke'a

Opiszemy teraz dokładniej kompletny model zaproponowany przez (Cooke 1991), oparty na metodzie średniej ważonej, w której wagi uzyskiwane są na podstawie wstępnego scoringu czyli ważonej sumy – znany jako klasyczny model Cooka.

W modelu tym występują eksperci wyrażający swoje opinie oraz decydent DM (Decision Maker) oceniający wiarygodność ekspertów.

Bazą do stworzenia teoretycznego modelu jest stwierdzenie, że konsensus, a więc proces zbierania ocen ekspertów musi być poddany następującym, podstawowym zasadom:

Powtarzalność: Wszystkie wyniki muszą być powtarzalne, zarówno model obliczeniowy jak i dane;

Odpowiedzialność: Źródła danych muszą być identyfikowalne, a same dane muszą pochodzić ze źródeł, z których są pozyskiwane;

Empiryczna kontrola: oceny eksperckie muszą być z zasady obserwowalne (możliwość falsyfikacji);

Neutralność: Proces pozyskania danych musi zapewnić, że rzeczywiste przekonania ekspertów zostaną zebrane (np. brak nacisków);

Uczciwość: Wszyscy eksperci muszą być traktowani identycznie.

Proces spełniający powyższe zasady nazywany jest racjonalnym konsensusem. Klasyczny model spełnia wszystkie zasady racjonalnego konsensusu.

W przypadku zmiennych ciągłych, model Cook'a wymaga, aby eksperci określili zestaw stałych percentyli q_r , $r = 1, \dots, k$, dla pewnych nieznanymi zmiennymi $\{X_1, \dots, X_n\}$ zwanych zmiennymi kalibrującymi. Decydent następnie określa wewnętrzny zakres (dolny i górny, $[q_{low}, q_{high}]$) każdej zmiennej dla eksperta i na tej podstawie buduje wagi kalibracyjne Cal .

Waga kalibracyjna eksperta e - $Cal(e)$, jest równa statystycznemu prawdopodobieństwu, że percentyl oceniany przez eksperta, odpowiada wynikowi eksperymentalnemu. Wagi ekspertów są obliczane w postaci tzw. scorów informacyjnych, na podstawie dwóch wielkości: wagi kalibracyjnej i sumy ważonych percentyli prawdopodobieństwa pokrycia zmiennych $\{X_i\}$.

Niech $p = \{p_1, \dots, p_n\}$ będzie poszukiwanym hipotetycznym rozkładem prawdopodobieństwa wartości zmiennej X ze zbioru alternatyw $\{1, \dots, n\}$ i niech $s = \{s_1, \dots, s_n\}$ będzie empirycznym rozkładem z N prób niezależnych pochodzących z rozkładu p . Wtedy względna informacja p w stosunku do s wynosi: $s \cdot \ln(s/p)$. Względna informacja również nazywana jest "entropią Kullbacka" lub "odległością Kullbacka-Leiblera".

Rozbieżność między P i S można mierzyć poprzez porównanie informacji $I(s,p)$ czyli rozkładu s względem p :

$$I(s,p) = \sum_i s_i \ln(s_i/p_i) \quad i = 1, \dots, n.$$

Można zauważyć, że dla dużych N mamy $Pr(2N I(s,p) \leq x) \rightarrow \chi^2_{n-1}(x)$. Wtedy $Cal(e)$, które jest prawdopodobieństwem uzyskania względnej informacji gorszej od zaobserwowanej, przyjmuje postać

$$Cal(e) = 1 - \chi^2_{n-1}(2N I(s,p)).$$

Kalibracja związana jest ze stopniem, w jakim rozkład uzyskany od danego eksperta jest skoncentrowany względem miary bazowej P .

Względną informację eksperta e dla danej zmiennej X_i uzyskuje się jako:

$$I(e) = \sum_i p_i \ln(p_i/r_i), \quad i = 1, \dots, n,$$

gdzie r_i jest miarą bazową dla przedziału q_i . Ogólna ocena informacji eksperta jest średnią informacji dla wszystkich zmiennych bazowych.

Wagi ekspertów są definiowane jako: $w_e = w'_e / W$, gdzie $w'_e = Cal(e) \cdot I(e) \cdot I_\alpha(Cal(e))$ oraz

$$W = \sum_e w'_e.$$

Biorąc to pod uwagę, jeżeli dla każdego eksperta skumulowany rozkład oznaczmy przez F_e to łączny rozkład jest równy $\sum_e w_e F_e$.

W powyższym modelu wagi opinii eksperckich oparte są na pomiarach ilościowych dotyczących informacji. Informacja mierzy stopień, w jakim niepewność skoncentrowana jest w rozkładzie opinii eksperta.

Miara ta może być realizowana zarówno w formie elicytacji¹ dyskretnej jak i percentylowej. W dyskretnym formacie, eksperci wyrażają niepewność co do zdarzeń, poprzez przypisanie zdarzeniom jednego z kilku predefiniowanych przedziałów prawdopodobieństwa - zwykle przyjmuje się następujące granice tych przedziałów: 10%, 20% ... 90%. W percentylowej formie, eksperci oceniają prawdopodobieństwo predefiniowanych percentyli, subiektywnego rozkładu niepewności - zwykle przyjmuje się do oceny następujące percentyle: 5%, 50% i 95%. Percentylowy format ma zazwyczaj przewagę nad formą dyskretną.

Pomiar informacji dokonywany jest w procesie kalibracji, który mierzy prawdopodobieństwo, że zestaw wyników doświadczalnych jest równy, w sensie statystycznym, z oceną eksperta.

Kalibracja przebiega w następujący sposób (Aspinall 2008). Dla danej wielkości, eksperci dzielą zakres swoich ocen na przedziały percentylowe, dla których odpowiadające im prawdopodobieństwa są znane. Dla przykładu weźmy podział na cztery przedziały: $p = \{0.10, 0.45, 0.30, 0.15\}$, gdzie $p_1 = 0.05$ oznacza, że prawdopodobieństwo wartości realizacji mniejszej niż lub równej ocenie pierwszego kwantyla wynosi 5%, $p_2 = 0.45$ oznacza prawdopodobieństwo realizacji, która byłaby większa niż pierwszy kwantyl i mniejsza lub równa drugiemu kwantylowi, itd.


Jeśli percentyle są ocenianych przez N ekspertów, każdy ekspert może być traktowany, jako hipoteza statystyczna H_0 :

H_0 : wartość realizowana mieści się w jednym z przedziałów percentylowych z wektorem prawdopodobieństwa P .

Wyniki ocen dla pojedynczego eksperta można przedstawić w postaci wektora $s(e) = \{s_1, s_2, \dots, s_4\}$


¹ elicytacja – metoda pozyskiwania wiedzy, w której nie prezentuje się gotowych odpowiedzi, lecz jedynie naprowadza na właściwe wnioski

Rozkład empiryczny ocen ekspertów dla danych k przedziałów percentylowych może być estymowany metodą największej wiarygodności przez zliczenie liczby realizacji, które wchodzą w dany przedział, podzielonej przez całkowitą liczbę N opinii (Westra 2011):



Rysunek 55. Schemat kalibracji w przypadku ekspertów, którzy udzielają odpowiedzi na pytania (zmiennie) bazowe. Liczba realizacji pokrywa się z odpowiednimi przedziałami $\{0.10, 0.45, 0.30, 0.15\}$. Źródło własne opracowane na podstawie (Westra 2011).

Inna metoda polega na wykorzystaniu podejścia regresyjnego, gdzie wagi nadawane są na podstawie „odległości” od funkcji regresji.



Rysunek 56. Schemat kalibracji regresyjnej dla trzech ekspertów oceniających percentyle= (0.05, 0.10, 0.50, 0.90, 0.95). Źródło opracowanie własne.

Jeśli realizacje są niezależne i pochodzą z rozkładu P wówczas można zdefiniować statystykę SWW, tak zwany statystyczny wskaźnik wiarygodności:

$$SWW = 2N \cdot I(s(e)|p) = 2N \sum_{i=1, \dots, k} \{s_i \ln(s_i/p_i)\}$$

gdzie $I(s(e)|p)$ jest względną informacją lub względną entropią (patrz np. Cover i Thomas, 1991) rozkładu s względem p dla eksperta e .

Statystyka SWW ma asymptotycznie rozkład chi-kwadrat (z $k-1$ stopniami swobody).

W zastosowaniach, kluczowe znaczenie dla praktyki ma również „kształt” rozkładu lub inaczej mówiąc rodzina rozkładów używana do szacowania prawdopodobieństwa.

Czasami używane rodziny rozkładów mogą być bardzo proste, takie jak:

- rozkład jednostajny – ekspert podaje zakres wartości $[a, b]$.
- rozkład trójkątny – obok zakresu ekspert ocenia modalną
- rozszerzenie rozkładu jednostajnego na szereg odcinków („schodki”) - oceniane jest względne prawdopodobieństwo w poszczególnych obszarach $[a_i, b_i]$ pokrywających cały zakres strat.

Bardziej skomplikowane metody polegają na wyborze rodzin rozkładów złożonych. W tym przypadku wykorzystuje się dodatkową, „zewnętrzną” wiedzę na temat mechanizmów mogących wpływać na „kształt” rozkładu np.: rodzina rozkładów normalnych czy też rozkładów gamma.

Ekspert ocenia odpowiednie parametry rozkładu na podstawie swojej wiedzy. Bardzo często, ekspert nie ocenia bezpośrednio „nieobserwowanych” parametrów rozkładu, ale pewne obserwowane statystyki, na podstawie których wyliczane są parametry np. metodą największej wiarygodności lub metodą momentów. Do takich statystyk należą: średnia, mediana, centyle itp.

W modelu można uwzględnić zewnętrzne czynniki, które mają duży wpływ na szacunki ryzyka. Np. szacunki wartości średnich można powiązać z czynnikami skali opisującymi wielkość zjawiska takimi jak: wskaźniki ryzyka KRI. Dodanie tych czynników do modelu zwiększa precyzję otrzymanych oszacowań.

Model bayesowski

Technika uzyskania i łączenia ekspertyz może być oparta na metodzie Bayesa (Shevchenko 2006). W tej metodzie, analityk prowadzący warsztaty tzw. Decision Maker (DM) korzysta z ocen prawdopodobieństwa szacowanych przez ekspertów, jako danych do aktualizacji swojej własnej oceny rozkładu, zwanej oceną *a`priori* w ramach metody Bayesa. Takie Podejście do agregacji opinii ekspertów zostało zaadoptowane przez Winkler (1968) i Morris (1974, 1977). Winkler (1968) oparł się na teorii rozkładów sprzężonych (conjugate), w którym prawdopodobieństwa *a`priori* i *a`posteriori* należą do tej samej rodziny parametrycznej. Obecnie częściej stosuje się podejścia nieparametryczne bazujące na symulacjach Monte Carlo.

Zbieranie opinii eksperckich w warunkach niepewności można rozpatrywać z punktu widzenia prawdopodobieństwa subiektywnego, powinniśmy wziąć pod uwagę paradygmat Bayesa, który pozwala na wprowadzenie preferencji jednostki w zakresie maksymalizacji oczekiwanej użyteczności. W podejściu Bayesa ocenę ekspertów na temat interesującego zdarzenia można aktualizować na podstawie ustosunkowanie się ich do dodatkowej informacji zawartej w tzw. zmiennych bazowych.

Wymaga to sformatowania procesu pozyskiwania wiedzy od ekspertów przy pomocy np. pytań ankietowych, tak aby formułowanie zdań ekspertów odbywało się w postaci szacowania rozkładu prawdopodobieństwa a`priori w oparciu o:

- charakterystykę zdarzenia
- zmienne bazowe
- opinie ekspertów w sprawie rozkładów zmiennych bazowych
- opinie ekspertów w sprawie interesujących zmiennych.

7.5. Model Supra-Bayes`a w ryzyku operacyjnym.

Podejście Supra-Bayesowskie opiera się w zasadzie na idei opisanej powyżej ale wprowadza pewną istotną modyfikację. Można ją opisać w następujący sposób: każda opinia jest wprowadzana przez decydenta. Z tym, że proces jest wieloetapowy, w pierwszym kroku decydent podejmuje decyzję co do wag opinii poszczególnych ekspertów, a następnie aktualizuje swój wcześniejszy pogląd na temat tych opinii. Pierwotnie metoda wprowadzona została przez Winkler (1968) i nazywana "metodą Supra Bayes`a", (Gregoriou 2009) (Genest 1985).

W podejściu Supra-Bayes`a, proces łączenia polega na zastosowaniu następującego algorytmu: podejmujący decyzję, w ramach tego podejścia zwany "Supra Bayes", a dotychczas nazywany analitykiem podejmującym decyzję (Decision Maker), definiuje swoje prawdopodobieństwo wystąpienia zdarzenia A ($P(A)$), następnie zbierane są opinie od ekspertów: $O_1, O_2, \dots, O_k$. Opinie ekspertów służą do obliczenia prawdopodobieństw z tzw. próbki ($P_1, P_2, \dots, P_k$). Ostatecznie korzystając z tych opinii, „Supra-Bayes” aktualizuje swoją opinię za pomocą wzoru Bayesa

$$P(E|P_1, P_2, \dots, P_k) \propto P(E) \cdot \ell(P_1, P_2, \dots, P_k|A)$$

Rozkład a`posteriori $P(A | P_1, P_2, \dots, P_k)$ może być postrzegany jako konsensus. Jest używany, jako rozkład apriori na dalszym etapie procesu modelowania np. łączenia z danymi historycznymi (wewnętrznymi lub zewnętrznymi), do obliczenia wartości ryzyka zgodnie z metodologią LDA (Roback 2001).

Podejście Supra-Bayesa jest zgodne ze wszystkimi czterema warunkami #1-#4 wymienionymi w poprzednim rozdziale. Ponadto, nie wymaga specjalistycznych, dodatkowych narzędzi informatycznych ani statystycznych umiejętności modelowania.

Pozostaje jednak podstawowa trudność, która wynika z faktu, że w równaniu Bayesa funkcja prawdopodobieństwa powinna być znana np. warunkowy rozkład prawdopodobieństwa opinii ekspertów, gdy wystąpi zdarzenie A. Supra Bayes, lub ktoś, kto musi ocenić funkcję wiarygodności, dokonuje oceny wag opinii ekspertów, ale równocześnie modyfikuje swoje wcześniejsze oszacowania, uwzględniając współzależność wyników itd. Podsumowując, podejście to wymaga połączenia dużej liczby opinii ekspertów.

Na szczęście, istnieją pomysły jak rozwiązać ten problem, zakładając bardziej realistyczny scenariusz, np. taki, że funkcja prawdopodobieństwa nie musi być określona w pełni. W szczególności, (Genest, Schervish 1985) zbudowali model dla takiej sytuacji, który może być stosowany w kontekście ryzyka operacyjnego.

Założmy, że badamy dotkliwość pojedynczego zdarzenia, dla którego chcemy zbudować model, czyli ciągły, jednowymiarowy rozkład prawdopodobieństwa. W analizach scenariuszy dla ryzyka operacyjnego, zakłada się, że rozkład jest elementem rodziny parametrycznej o parametrze θ , a zadaniem eksperta jest oszacować ten parametr.

Najczęściej stosowany w takich przypadkach jest rozkład log-normalny, dla którego eksperci szacują średnią i odchylenie standardowe. Inne rozwiązania to rozkład trójkątny, lub rozkład PERT, w przypadku tych ostatnich, eksperci oszacowują minimalne, najbardziej prawdopodobne (typowe) i maksymalne wartości.

Ograniczenie się do powyższych rozkładów jest jednak bardzo restrykcyjnym założeniem i niekoniecznie prowadzi do właściwych rezultatów. Dotkliwość zdarzeń operacyjnych w rzeczywistości ma z natury rozkład leptokurtyczny (z długim prawym ogonem), który nie jest dostatecznie opisywany przez te rozkłady. Nawet rozkład log-normalny jest dobrym przybliżeniem tylko do 70% centyla. Wyniki wielu badań sugerują, że powinniśmy stosować rozkłady mieszane czyli rozkłady należące do różnych rodzin dla różnych przedziałów wartości np. dla wartości skrajnych najbardziej odpowiednie są rozkłady z teorii wartości ekstremalnych takie jak uogólniony rozkład Pareto. Zakładamy więc, że każdy z ekspertów wyraża swoje stanowisko na wielkość θ w ten sposób, że prawdopodobieństwa są oceniane na rozłącznych fragmentach domeny θ . Wadą tych rozkładów jest fakt, że są to bardzo skomplikowane i nieintuicyjne rozkłady i zazwyczaj eksperci nie są w stanie ocenić z dostatecznym stopniem dokładności ich parametrów.

Rekomendowane jest podejście oparte na tzw. czasie trwania (duration), w którym eksperci proszeni są o oszacowanie czasu pomiędzy zajściem zdarzeń o różnych skutkach finansowych. Prawdopodobieństwa w odpowiednich przedziałach są budowane na podstawie tych szacunków. Czas trwania - duration wyraża się wzorem:

$$d(x) = \frac{1}{\lambda(F(y; \theta) - F(x; \theta))}$$

W modelu statystycznym, zakładamy, że dziedziną θ jest ograniczony podzbiór na $R(\theta)$, którego granice $a_0 = \inf \{\theta \in \Theta\}$ i $a_k = \sup \{\theta \in \Theta\}$ są skończone. Będziemy zakładać, że dziedzina Θ jest podzielona przez punkty $a_0 < a_1 < \dots < a_k$. Dalej niech $t_j = (a_{j-1}, a_j)$ oraz $p_i = (p_{i1}, p_{i2}, \dots, p_{in})$, gdzie p_{ij} jest opinią i-tego eksperta w zakresie oceny wartości parametru $\theta \in t_j$. Jeśli mamy k ekspertów uczestniczących w warsztatach, uzyskamy w efekcie macierz $p = (p_1, p_2, \dots, p_k)$, gdzie każde p_i jest n -wymiarowym wektorem. Podobnie jak w przypadku ekspertów, Supra-Bayes nie jest w stanie oszacować dokładnie rozkład θ . Tak więc będzie on również odpowiadał na te same pytania co eksperci.

Matematycznie, podejście Supra-Bayes`owskie pozwala wprowadzić dodatkowy wektor p prawdopodobieństw na tym samym zestawie przedziałów $\{t_i\}$. Wówczas uśrednione prawdopodobieństwo $P^* = P(A | P_1, P_2, \dots, P_k)$ możemy przedstawić w postaci równania:

$$P^* \propto p \cdot \text{lik}(P|\theta \in t_j)$$

Do rozwiązania powyższego równania potrzebna jest znajomość funkcji wiarygodności Lik. Aby zamodelować funkcję Lik, możemy skorzystać z metody zaproponowanej przez (Genest i Schervish 1985), która wykorzystuje twierdzenie Bayesa. Tym razem, dla każdego przedziału I_j , Supra-Bayes musi określić tylko pierwszy moment tzn. wartość oczekiwaną brzegowych rozkładów F_j . Wektor ten oznaczmy $M_j = (\mu_{1j}, \mu_{2j}, \dots, \mu_{kj})$. Należy pamiętać, że nie jest wymagane określenie warunkowego rozkładu. W przypadku ryzyka operacyjnego, wektor M można przetłumaczyć np. na zadanie dla szefa linii biznesowej, który ma odpowiedzieć na to pytanie: jaki czas (duration) wybiorą twoi eksperci jako najbardziej prawdopodobny dla danego prognozy straty? Szef linii biznesowej powinien być w stanie zidentyfikować zarówno bardziej konserwatywnych jak i śmiałych członków zespołu.

Genest i Schervish (1985) pokazali, że przy zachowaniu bardzo prostych i intuicyjnych metod problem ten daje się rozwiązać w postaci liniowej poprawki do początkowego wektora p . W ich podejściu mamy do czynienia z sytuacją, w której Supra-Bayes chce wykorzystać opinię ekspertów do zmodyfikowania swojej oceny p (dotyczy to każdego zakresu I_j) prawdopodobieństwa zdarzenia A . Opinie ekspertów reprezentowane są przez wektor prawdopodobieństw $(q_1, \dots, q_n)$ dotyczących zdarzenia A . Opinie ekspertów mogą być traktowane jako zmienne losowe Q_i , których wartości realizacji q_i są wykorzystywane przez Supra-Bayesa. Zgodnie z twierdzeniem Bayesa trzeba zmodyfikować pierwotną opinię o prawdopodobieństwie A równym p w następujący sposób:

$$p^* = \frac{p \Pr(Q = q|A)}{\Pr(Q = q)}$$

Powyższe równanie, aby mogło być użyte w praktyce, wymaga aby Supra-Bayes dokonał ilościowych ocen wszystkich ekspertów pod kątem ich wiarygodności oraz oszacował informację zawartą w ich ocenach. Innymi słowy Supra-Bayes powinien dokładnie oszacować prawdopodobieństwa $(q_1, \dots, q_n)$ zarówno przed zajściem zdarzenia A jak i w przypadku zajścia zdarzenia A . Istnieje rozwiązanie powyższego problemu, aczkolwiek niemożność oszacowania łącznego rozkładu A i Q skutkuje tym, że korekta p^* nie jest jednoznaczna. Wyjściem z tej sytuacji jest założenie pewnej funkcyjnej formy na $p^*(q)$, która byłaby odpowiednio prosta i intuicyjna. Okazuje się, że w tym celu trzeba zdefiniować warunek spójności oraz żądanie aby korekta spełniała ten warunek.

Warunek Spójności (WS). Bez względu na to, jaki jest rozkład brzegowy F dla rozkładu Q musi istnieć wspólny rozkład prawdopodobieństwa A i Q , który jest kompatybilny z F , tzn. spełniający wymagania warunku aby $p^*(q) = \Pr(A|Q = q)$.

Założmy, że wstępna specyfikacja, którą dokonuje Supra-Bayes składa się z prawdopodobieństwa a priori p i wektora średnich $E(Q) = (\mu_1, \dots, \mu_n)$. (Genest Schervish 1985) pokazali, że jedyną formułą $p^*(q)$, która spełnia WS jest liniowa kombinacja q_s oraz p :

$$p^*(q) = p + \sum_{i=1}^n w_i (q_i - \mu_i)$$

gdzie wagi w_i mogą być ujemne. Spełniają one rolę korelacji pomiędzy Q_i oraz A , oszacowaną przez Supra-Bayesa.

Jeżeli dodatkowo przyjmie się, że wagi w_i są nieujemne, co w sposób naturalny jest wykorzystywane w przypadku zastosowań do ryzyka operacyjnego, muszą być spełnione poniższe nierówności:

$$\max \left\{ \sum_{i=1}^n \frac{w_i \mu_i}{p}, \sum_{i=1}^n \frac{w_i (1 - \mu_i)}{1 - p} \right\} \leq 1$$

Zestaw powyższych warunków pozwala na wyznaczenie wag w_i , choć nie są one wyznaczone jednoznacznie.

7.6. Modele dla zagregowanej straty – wykorzystanie scenariuszy do budowy modeli częstości i dotkliwości.

Model podstawowy ryzyka operacyjnego budowany jest głównie w oparciu o dane wewnętrzne, a opiera się na podejściu związanym z estymacją rozkładu prawdopodobieństwa strat. Oddzielnie szacuje się rozkład częstości zdarzeń w zadanym horyzoncie czasowym, a oddzielnie dotkliwości pojedynczych zdarzeń. Rozkład strat uzyskiwany jest poprzez splot rozkładu dotkliwości z rozkładem częstości (tzw. model aktuarialny LDA) (Temnov 2008).

Banki zbierają dane wewnętrzne przez wiele lat. Te wewnętrzne dane o stratach, można uznać za aktualny stan wiedzy historycznej do budowy wewnętrznych modeli ryzyka operacyjnego. Ograniczony horyzont czasowy zbierania danych historycznych jest źródłem poważnych obciążeń. Wiele strat różnych typów i wielkości, które miały miejsce w innych instytucjach finansowych niekoniecznie musiały zdarzyć się w konkretnym banku. W ramach systemu pomiaru ryzyka bank powinien dobrać do swoich danych wewnętrznych również oceny tych zewnętrznych strat w celu uwzględnienia potencjalnego wpływu takich strat na swój profil ryzyka. Zwykle proces łączenia tych strat z danymi wewnętrznymi przebiega w oparciu o odpowiednie procedury skalujące, biorące pod uwagę aktualny stan profilu ryzyka banku. Tym nie mniej opinie ekspertów stanowią również bardzo istotne źródło danych, które muszą być wykorzystane w procesie szacowania ryzyka. W niniejszym rozdziale zostanie omówiona problematyka łączenia modeli uzyskanych na podstawie danych historycznych z prognostycznymi danymi jakimi są opinie ekspertów. Jako dane historyczne rozumiane będą dalej połączone dane wewnętrzne i zewnętrzne.

Rozważmy następujący przykład, który będzie przewijał się w dalszej części rozdziału. Bank poniósł 10 mln PLN strat z tytułu strat powstałych na skutek szkody w aktywach rzeczowych w wyniku klęsk żywiołowych lub innych wydarzeń np.: na wprowadzenie dodatkowych zabezpieczeń technicznych w miejscach najbardziej narażonych na akty wandalizmu. Do wykorzystania tej informacji trzeba wziąć pod uwagę okoliczności, które spowodowały wystąpienie tej straty. Kwantyfikacja tych okoliczności odbywa się najczęściej poprzez tzw. wskaźniki ryzyka KRI (Key Risk Indicators), dzięki którym można dokonać korekty modeli obliczania ryzyka np. z uwagi na zmiany procedur zapobiegania i kontroli. Po dokonaniu oceny sytuacji (obecny stan) i uwzględnieniu ewentualnych korekt, eksperci banku stwierdzili, że podobne straty w tej wysokości mogą zdarzyć się raz na 5 lat i że takie zdarzenie w mniej sprzyjających warunkach, spowoduje w banku 15 milionów PLN strat. Są to w rzeczywistości dane prognostyczne, w banku może dojść do szeregu strat w zakresie np.: 5 mln do 20 milionów PLN. Problemem, którym będziemy się teraz zajmować jest integracja scenariusza eksperckiego z danymi historycznymi.

Założmy, że bank zbiera dane o stratach w ciągu ostatnich trzech lat. W celu uzupełnienia tych danych generuje scenariusze dla strat ze zdarzeń operacyjnych, których prawdopodobieństwo wystąpienia szacowane jest następująco: raz na 5 lat uzyskuje się na podstawie scenariusza stratę w wielkości 15 milionów PLN. Interpretowanie tego, jako kolejną obserwację, którą należy dodać do danych historycznych o stratach zaobserwowanych do tej pory nie jest dobrym rozwiązaniem. W ten sposób bank powinien postąpić tylko raz w ciągu pięciu lat. Złożmy, że w innym scenariuszu mamy 10 milionów PLN strat z możliwością ich wystąpienia raz na 1.5 roku. Dodanie takiego scenariusza do danych wewnętrznych zebranych w ciągu trzech lat, spowoduje „rozcieńczenie” efektu danych scenariuszowych. W takim przypadku, mówiąc w uproszczeniu, do naszych danych wewnętrznych powinniśmy dodać dwie takie wartości scenariuszowe. Nie tylko wysokość potencjalnej straty, ale i jej częstotliwość muszą być uwzględnione przy wykorzystaniu scenariusza. Ten intuicyjny algorytm opisuje filozofię, która leży u podstaw metody, odpowiedniego integrowania danych scenariuszowych z danymi wewnętrznymi.

Istotnym problemem występującym przy integracji danych scenariuszowych z danymi historycznymi jest to, że trzeba brać pod uwagę częstotliwości danych scenariuszowych. Na podstawie modeli kalibrowanych na podstawie zarówno danych historycznych jak i eksperckich oblicza się różne biznesowe wskaźniki, które następnie służą do oszacowania kapitału ekonomicznego. Wyliczone są również wskaźniki, które służą do oceny rentowności: produktów, klientów, linii biznesowych. Błędne oszacowanie ryzyka może spowodować istotne zaburzenia procedur zarządzania. Nierealne wartości kapitału są często konsekwencją włączania informacji o dotkliwości strat bez uwzględnienia informacji o częstotliwości (Van Leyveld 2007).

Bardzo istotny jest poziom szczegółowości, na podstawie którego bank oblicza ryzyko operacyjne. Ryzyko bazujące na danych historycznych obliczane jest często w skali jednostek („komórek”) wyznaczanych przez linię działalności biznesowej i typ zdarzenia powodującego straty. Czasami mniejsze linie biznesowe czy rzadziej spotykane rodzaje strat są łączone ze sobą, tworząc jedną „komórkę”. Tymczasem scenariusze budowane są w oparciu o podejście procesowe, to znaczy w oparciu o możliwe powiązania przyczyn i skutków wystąpienia zdarzenia. Dlatego integrując wyniki obserwacji historycznych i scenariuszowych trzeba dokładnie zdefiniować zakres scenariusza oraz danych historycznych, które chcemy połączyć.

Kontynuując przykład z prognozowaną stratą 15 milionów PLN występującą raz na 5 lat, będziemy łączyli ten scenariusz z istniejącymi danymi wewnętrznymi, w tym celu musimy konsekwentnie odtworzyć wewnętrzne dane przez okres pięciu lat na podstawie trzyletnich danych historycznych znajdujących się w bazie. Tylko wtedy możemy dodać 15 milionów PLN straty wynikającej ze scenariusza do danych wewnętrznych. Innymi słowy, używamy aktualnego stanu trzech lat obserwacji wewnętrznych o stratach, do wygenerowania wystarczającej liczby danych „historycznych”, które moglibyśmy integrować ze scenariuszem. Mamy do czynienia z dwoma różnymi stanami - obecnym i przyszłym. Metodologia integracji powinna polegać na prognozowaniu strat w horyzoncie czasowym zgodnym ze scenariuszem lub z danymi historycznymi.

Bieżące prawdopodobieństwo straty – dotyczy to zarówno dotkliwości jak i częstotliwości – szacuje się na podstawie danych historycznych w poszczególnych „komórkach”. Mamy do dyspozycji wiele rozkładów pochodzących z różnych rodzin, które możemy wykorzystać do budowy modelu. Oczywiście, zadaniem jest budowa optymalnego modelu, czyli najlepiej dopasowanego do danych

historycznych, w oparciu o obiektywne kryteria. Często nie jest jasne, który model wybrać, gdyż zdarza się, że wg jednego kryterium dany model jest nieznacznie lepszy od innych, a wg innego kryterium dany model nie jest najlepszy. Nie ma jednej miary oceny jakości modelu. Jeżeli w danej „komórce” mamy dużo zdarzeń, wówczas metody statystyczne dają dużą stabilność wyboru modelu (Panjer 2006).

Praktyki pomiaru z wykorzystaniem danych scenariuszowych

Poniższy rozdział oparty został na pracy (Dutta K., K., Babbel D., F. 2010), która daje matematyczną podstawę integracji danych historycznych i scenariuszowych.

Do kalibracji modeli wykorzystywane są: dane wewnętrzne, dane zewnętrzne i scenariusze eksperckie. Trzeba pamiętać, że dane zewnętrzne są wydarzeniami historycznymi, które miały miejsce w innych instytucjach i zawierają informacje o innych rozkładach prawdopodobieństwa. Dane generowane na podstawie danych wewnętrznych i zewnętrznych nie uwzględniają hipotetycznych sytuacji, które powinny być również brane pod uwagę. Dlatego używa się scenariuszy, ale przy okazji warto podkreślić fakt, że dane scenariuszowe nie muszą odzwierciedlać historycznych strat, które rzeczywiście miały miejsce.

Rozkład częstości zdarzeń mówi nam o tym, jak wiele strat będzie musiało wystąpić, aby odnotować stratę danej wielkości. Różnica pomiędzy rozkładem częstości, a dotkliwością polega na tym, że ten pierwszy kalibruje się w tylko oparciu o dane wewnętrzne – do jego estymacji nie używa się danych zewnętrznych, oprócz tego przy modelowaniu nie bierze się pod uwagę problemu tzw. „ciężkich ogonów”, więc zazwyczaj wykorzystuje się prostsze rodziny rozkładów np. rozkład Poissona lub jego odmiany np. ujemny dwumianowy. Zaletą rozkładu Poissona jest w tym przypadku dostępność prostej i w miarę dokładnej metody szacowania parametru, wartość parametru wyliczana jest, jako średnia liczba strat w ciągu danego okresu czasu, najczęściej jednego roku.

W naszej analizie będziemy używali danych scenariuszowych, jako potencjalnych, możliwych strat. Subiektywność i ewentualne obciążenia są nieodłączną cechą danych scenariuszowych. Metody interpretacji scenariuszy muszą brać to pod uwagę.

Dane scenariuszowe wykorzystywane do obliczeń ryzyka operacyjnego mają dwa wymiary - dotkliwość i częstotliwość. Dotkliwość może być estymowana punktowo np. 20 milionów PLN lub zakresowo np. od 15 miliona dolarów do 25 milionów PLN). Dla celów ryzyka operacyjnego, bardzo wygodna jest druga ewentualność, a mianowicie możliwość szacowania zakresów - łatwiej jest określić zakres możliwej straty niż jej najbardziej prawdopodobną wielkość. Jest to również zgodne z założeniem o ciągłym charakterze rozkładu dotkliwości. Możemy sztucznie konwertować estymację punktową do estymacji przedziałowej, biorąc ją jako wartość środka zakresu i przyjmując granice: $\pm p\%$, jest to jednak dość kłopotliwe z uwagi na fakt, że określenie granic w ramach scenariusza jest mało dokładne i zawiera obciążenia związane z „ostrożnościowym” formułowaniem sądów. Częstotliwość jest szacowana w postaci ilorazu $\frac{m}{t}$, gdzie m oznacza ile razy wydarzenie będzie mieć miejsce w ciągu t okresów. Najczęściej przyjmowaną długością okresu jest jeden rok, stąd w dalszej części będziemy używali tej wielkości, tym bardziej, że biznesowe wykorzystanie pomiaru ryzyka dokonywane jest w stosunku rocznym. To pozwala szacować prawdopodobieństwo, jako stosunek liczby m zdarzeń, które wystąpią w próbie o liczebności $t \cdot n$, gdzie n jest liczbą strat obserwowanych rocznie w danej

„komórce”, a t długością okresu. Podobnie jak w przypadku dotkliwości, dla częstości możemy tworzyć zakresy, takie jak: m zdarzeń w przedziale czasu $[t_1, t_2]$. W tym przypadku m oznacza liczbę zdarzeń, które mogą wystąpić w okresie od t_1 do t_2 lat, co może na przykład odpowiadać scenariuszowi najgorszemu i najlepszemu. Alternatywnie można interpretować powyższy zapis, jako średnia wartość zdarzeń pomiędzy t_1 i t_2 . Z uwagi na subiektywny charakter oceny scenariuszy istotne jest zbudowanie prostego i zrozumiałego modelu, który byłby identycznie interpretowany przez wszystkich ekspertów.

Tutaj zrobimy założenie, które będziemy dalej używać, że rozkłady częstości i dotkliwości pozostają stałe w ciągu (krótkiego) okresu czasu takiego jak np. rok. Dzięki temu nie musimy skalować danych wewnętrznych o obrębie tego odcinka czasowego.

Powyższe założenie jest równoważne stwierdzeniu, że zmiany w środowisku biznesowym dokonują się stosunkowo powoli. Jest to ważne w tym sensie, że własności modeli powinny odpowiadać charakterowi danych eksperckich. Dane do scenariuszy eksperckich zbierane są zazwyczaj raz do roku.

Metodologia

Trzeba zwrócić uwagę, że mamy do czynienia z dwoma rodzajami prezentacji prawdopodobieństwa zdarzenia. Jednym z nich jest historyczna miara prawdopodobieństwa uzyskana na podstawie danych o stratach rzeczywistych i rozumiana jako „domniemane” prawdopodobieństwo. Można argumentować, że historyczna miara prawdopodobieństwa powinna być oparta na wewnętrznych i zewnętrznych danych. Problemem łączenia danych wewnętrznych i zewnętrznych jest procedura pozyskiwania tych danych. Przy zbieraniu danych zewnętrznych występuje nadreprezentacja, rozumiana jako obciążenie, zdarzeń o dużej dotkliwości, ponieważ głównie takie zdarzenia podlegają rejestracji w konsorcjalnych lub publicznych bazach.

Stosowane są różne podejścia do rozwiązania problemu integracji danych. Pierwszy oparty jest na zastosowaniu tzw. próbkowania obciążonego (importance sampling) i opiera się na oszacowaniu funkcji obciążenia. Dla „komórek” banku, dla których mamy wystarczającą ilość zdarzeń wewnętrznych obliczamy funkcję obciążenia w stosunku do podobnych zdarzeń z baz zewnętrznych. Następnie wykorzystujemy tę funkcję do algorytmu „mieszania” danych z różnych źródeł. Inne podejście bliższe do podejścia relacyjnego przyjmuje, że iloraz wiarygodności strat (likelihood ratio) między zdarzeniami zewnętrznymi i wewnętrznymi jest stały w różnych „komórkach”. Możemy porównywać te ilorazy na bazie danych wewnętrznych i zewnętrznych, a następnie uwzględnić je w postaci korekty prawdopodobieństwa przy integracji. W opisanych przypadkach, procedura nie zależy od modelu parametrycznego szacowania rozkładu w „komórkach”.

Wg metodologii omawianej tutaj będziemy rozpatrywali metodę łączenia danych historycznych ze scenariuszami, w tym celu trzeba dopasować miarę częstotliwości do każdego zdarzenia z zestawu scenariuszy na znormalizowanej skali. Precyzyjniej rzecz ujmując, historyczną dotkliwość i częstotliwość będziemy przekształcali do odpowiedniego rozkładu, a następnie ocenimy wpływ każdego scenariusza na zmiany rozkładu.

Bez straty ogólności, oznaczymy zdarzenie, jako odcinek na dodatniej osi rzeczywistej $\mathbb{R}^+$. Dla celów praktycznych, nasze zdarzenie będzie ograniczone do przedziału postaci: $[a, b]$. Mówimy, że

wydarzenie $[a, b]$ wystąpiło, gdy widzimy w naszej próbie wartości x takie, że $a \leq x \leq b$. W tym miejscu zauważmy, że występuje problem związany z tym, że szacunki ekspertów dokonywane są z pewną dokładnością i powinniśmy posługiwać się dystrybucją empiryczną, która nie jest funkcją ciągłą. Zgodnie z twierdzeniem Dvoretzky-Kiefer-Wolfowitz-Massart (DKWM) dystrybucja empiryczna dąży do ciągłej dystrybucji rozkładu jednostajnie. Na tej podstawie można skonstruować odpowiedni dla naszych celów ciągły estymator dystrybucji.

Jeżeli $x_1, \dots, x_n$ będzie próbą z rozkładu F to możemy zdefiniować statystykę pozycyjną $x_{1:n} \leq x_{2:n} \leq \dots \leq x_{n:n}$. Niech $H_j = \min\{x_{j:n} - x_{j-1:n}, j = 2, 3, \dots, n\}$, wówczas można zbudować estymator jądrowy $\tilde{F}_n(x)$, który będzie ciągły, a jednocześnie będzie dostatecznie blisko dystrybucji rozkładu F . Konstrukcja takiego estymatora może przebiegać następująco (Ciesielski 2008):

$$\tilde{F}_n(x) = \frac{1}{n} \sum_{j=1}^n K\left(\frac{x - x_j}{H_n}\right)$$

gdzie

$$K(t) = \begin{cases} 0, & \text{dla } t \leq -0.5 \\ k(t), & \text{ciągłe i niemalejące dla } t \in (-0.5, 0.5) \\ 1, & \text{dla } t \geq 0.5 \end{cases}$$

Na mocy nierówności DKWM mamy:

$$Pr_F \left\{ \sup_{x \in R} |\tilde{F}_n(x) - F(x)| \geq \varepsilon \right\} \leq 2e^{-2n(\varepsilon - 0.5n)^2}$$

W dalszej części możemy zakładać, że mamy ciągły rozkład strat F co oznacza, że prawdopodobieństwo straty będzie dążyło do 0 gdy $a \rightarrow b$.

Definiujemy zakres zdarzenia jako $[a, b]$, gdy obie granice są skończone. Jednakże, z definicji nie są to jedyne wydarzenia. Możemy mieć zdarzenia, choć nie będą zbyt użyteczne dla naszych celów, w postaci $[a, \infty)$ lub $[0, \infty)$. Dzięki temu przestrzeń zdarzeń posiada miarę σ -skończoną.

Obliczanie historycznej miary prawdopodobieństwa

Zaczynamy od budowy modelu na danych wewnętrznych. Jak wspominaliśmy wcześniej, one są najważniejszym elementem budowy modelu wewnętrznego ryzyka. Niech $f(x)$ będzie funkcją gęstości prawdopodobieństwa dotkliwości strat w banku dla danej „komórki”. Prawdopodobieństwo zdarzenia $[a, b]$ lub mówiąc bardziej dokładnie, prawdopodobieństwo strat związanych z tym zdarzeniem jest równe:

$$\mu = \int_a^b f(x) dx$$

Nazywamy μ prawdopodobieństwem zdarzenia na $[a, b]$ i oznaczamy przez $\mu([a, b])$. Miara prawdopodobieństwa jest miarą w sensie ogólnym. W niniejszej pracy, będziemy używać słowo "prawdopodobieństwo" w znaczeniu "miara prawdopodobieństwa" i po prostu nazwać miarą $[a, b]$.

Należy pamiętać, że $f(x)$ jest ciągła czyli $\mu([a, b]) = \mu((a, b)) = \mu((a, b]) = \mu([a, b))$. Trzeba również zauważyć, że kiedy $a \rightarrow b$ wówczas $\mu \rightarrow 0$, innymi słowy, gdy zakres zdarzenia dąży do zera, prawdopodobieństwo jego wystąpienia (częstotliwość) również dąży do zera. Będziemy interpretować powyższą miarę zgodnie z interpretacją częstotliwościową (podejście bayesowskie wykorzystywane będzie tylko w kontekście prawdopodobieństwa warunkowego). Jeśli losowo wygenerujemy n liczb z rozkładu opisywanego funkcją gęstości prawdopodobieństwa $f(x)$ i będziemy powtarzać losowanie wystarczającą ilość razy, to możemy spodziewać się $n \cdot \mu$ obserwacji x takich, że $a \leq x \leq b$.

Miara μ jest ustalana przez rozkład dotkliwości, dla częstotliwości czyli liczby zdarzeń n będziemy musieli zdefiniować nową zmienną losową i nową miarę. Niech $\lambda(n)$ będzie funkcją gęstości prawdopodobieństwa częstotliwości wewnętrznych strat dla samej „komórki”. Weźmy pod uwagę fakt, że rozkład $\lambda(n)$ jest dyskretny, czyli n jest liczbą dodatnią, całkowitą występującą z prawdopodobieństwem $\lambda(n)$.

Łącząc obie definicje miar dla częstości i dotkliwości widzimy, że z prawdopodobieństwem $\lambda(n)$ liczba $n\mu$ obserwacji będzie obserwowana w przedziale $a \leq x \leq b$. W naszym rozumieniu, $f(x)$ i $\lambda(n)$ są rozkładami dotkliwości i częstotliwości strat w „komórce”, które będziemy szacować z wykorzystaniem wewnętrznych danych o stratach. Będziemy odwoływać się do rozkładu dotkliwości i częstotliwości, jako rzeczywistych rozkładów opartych na historycznej mierze prawdopodobieństwa.

Dane z analiz scenariuszowych będą dołączane do danych wewnętrznych na podstawie których szacowane jest prawdopodobieństwo tego samego typu zdarzeń na $[a, b]$, a zatem, wpływać będą na korektę rozkładu. Teoretycznie możemy oprzeć miary prawdopodobieństwa: $f(x)$ i $\lambda(n)$ na scenariuszach ale może to dać rozkłady zupełnie inne od tych, uzyskanych stosując dane historyczne jako bazowe (w sensie rodzin prawdopodobieństwa). W naszej metodologii szacunki rozkładów oparte na danych scenariuszowych będą różnić się od swoich odpowiedników szacowanych na bazie historycznej tylko pod względem wartości parametrów.

Jak wspomniano powyżej, dane scenariuszowe są hipotetycznymi danymi, których bank jeszcze nie doświadczył. Takie straty mogą, ale nie muszą być obserwowane w przyszłości. Dlatego będziemy odnosić się do korekty spowodowanej scenariuszem, jako zmodyfikowanej, „domyślnej” miary prawdopodobieństwa dotkliwości i częstości implikowanej przez dane historyczne. Podobnie prawdopodobieństwo, które otrzymujemy na podstawie danych opartych na scenariuszach związane będzie z tym szczególnym zbiorem scenariuszy.

Obliczanie uzgodnionej miary prawdopodobieństwa

W tym miejscu zajmujemy się problemem łączenia rozkładów uzyskanych na podstawie danych historycznych i scenariuszy.

Dotkliwość straty powstałej w wyniku zdarzenia definiuje się jako przedział $[a, b]$, a częstotliwość w kategorii stosunku m/t , gdzie m zdarzeń może wystąpić w ciągu t lat. Przy definiowaniu miary prawdopodobieństwa dla danego scenariusza, trzeba uwzględnić fakt, że liczba zdarzeń dla przedziału $[a, b]$ powinna być równa m/t . Jeśli historyczna częstotliwość równa n jako zmienna losowa ma rozkład $\lambda(n)$, w ciągu t lat możemy spodziewać się, że łączna liczba zdarzeń $l = \sum_{i=1}^t n_i$, gdzie liczby n_i są niezależne i mają rozkład $\lambda(n)$.

Założmy, że dla zdarzeń z przedziału $[a, b]$, mamy m zdarzeń zgodnie ze scenariuszem (w sensie prawdopodobieństwa), tymczasem w danych historycznych obserwujemy k zdarzeń (spodziewamy się, że liczba zdarzeń zachodzących na $[a, b]$ jest równa $l\mu$). Jeśli k jest mniejsze niż m , generujemy $m-k$ zdarzeń w zakresie $[a, b]$ z generatora o rozkładzie określonym na podstawie danych historycznych i łączymy z l zdarzeniami pochodzącymi z danych historycznych. Następnie estymujemy rozkład dotkliwości na podstawie połączonych danych gdzie l jest liczbą obserwacji historycznych, a $m - k$ obserwacji pochodzi z generatora o rozkładzie zgodnym z rozkładem historycznej dotkliwości w przedziale $[a, b]$. Tak uzyskany rozkład dotkliwości nazywać będziemy uzgodnionym rozkładem dotkliwości ze względu na scenariusz: który przewiduje na $[a, b]$ wystąpienie m zdarzeń w ciągu t lat.

Z praktycznego punktu widzenia, l zazwyczaj jest znacznie większe niż $m - k$, dlatego najlepszym wyjściem jest wykorzystanie rozkładu szacowanego na podstawie danych historycznych. W takim przypadku procedura sprowadza się do ponownego oszacowania parametrów historycznego rozkładu dotkliwości.

Należy pamiętać, że procedura uzgodnienia rozkładu dotkliwości jest wrażliwa na wartość l , jest to zmienna losowa o rozkładzie, który jest splotem $F_{\lambda(n)}^*$ l liczb pochodzących z $\lambda(n)$. Dlatego też opisana procedura uzgodnienia rozkładu jest uzgodnieniem z realizacją l . Możemy teraz wprowadzić bardziej precyzyjną notację do opisu obliczeń, które wykonaliśmy. Przez $G_l^S(x)$ oznaczmy uzgodniony rozkład dotkliwości scenariusza S ze względu na realizację l . Bardziej ogólnie, jeśli $\psi = \{s_1, s_2, s_3, \dots, s_r\}$ jest zbiorem scenariuszy, to $G_l^\psi(x)$ oznacza uzgodniony rozkład dotkliwości ze względu na łączny scenariusz. Podstawowym problemem jest zachowanie częstotliwości zdarzeń scenariuszowych.

Kalkulacja dla łącznego scenariusza ze zbioru $G_l^\psi(x)$ jest bardzo podobna, jak w przypadku pojedynczego scenariusza. Scenariusz s_i , w ma zakres dotkliwości wartość $[a_i, b_i]$ oraz częstotliwość m_i/t_i . Każdy scenariusz jest wyrażony w innym zakresie wartości. Oznaczmy przez $T = \max(t_i)$. Jeśli m_i zdarzeń s_i występuje w latach t_i to po T lat powinniśmy mieć $T \frac{m_i}{t_i}$ zdarzeń s_i . Skorzystaliśmy z prostej liniowej ekstrapolacji (można również użyć stochastycznej ekstrapolacji na podstawie rozkładu częstotliwości). W przypadku rozkładu Poissona dla modelu częstotliwości, łatwo można zauważyć, że liniowa ekstrapolacja jest bardzo bliska stochastycznej. Innymi słowy, mamy algorytm normalizacji różnych częstotliwości na wspólną podstawę.

Po normalizacji każdego scenariusza w dziedzinie częstotliwości, mamy scenariusze s_i lub inaczej dotkliwości $[a_i, b_i]$ i częstości k_i , które uwzględniają skumulowany efekt nakładania się zdarzeń z innych scenariuszy. W przypadku, gdy mamy więcej niż jeden scenariusz, konieczne jest wydzielenie częstotliwości każdego scenariusza. Na przykład, jeśli mamy dwa scenariusze o dokładnie tej samej częstotliwości i dotkliwości, to w naszej próbie historycznej również musimy mieć liczbę wystąpień zdarzenia równą lub większą od sumy częstotliwości obu scenariuszy. Możliwe jest również, że dotkliwości scenariuszy mogą się częściowo pokrywać. Mogą wystąpić następujące przypadki:

- zakresy dotkliwości scenariuszy są całkowicie rozłączne z innymi scenariuszami,
- zakresy dotkliwości scenariuszy pokrywa się, całkowicie lub częściowo z innymi scenariuszami w zbiorze scenariuszy.

W takich przypadkach liczby k_i powinny zostać skorygowane wg następujących metod:

- zakres dotkliwości związany ze scenariuszem jest całkowicie rozłączny od innych scenariuszy jego częstotliwość pozostaje bez zmian.
- zakresy dotkliwości innych scenariuszy pokrywają nasz scenariusz całkowicie lub częściowo, musimy obliczyć łączną częstotliwość dla każdego scenariusza z uwzględnieniem korekty na nakładanie. Uwzględniać będziemy tylko pary nakładających się scenariuszy traktując nakładanie się większej liczby scenariuszy jako zaniedbywalnie małą wielkość.

W tym celu musimy zdefiniować tzw. macierz korekty dla par scenariuszy $R = (r_{ij})_{1 \leq i, j \leq r}$, gdzie i numeruje pierwszy scenariusz, a j numeruje drugi scenariusz (r jest liczbą scenariuszy). Sortujemy zbiór scenariuszy w odniesieniu do dolnej granicy ich zakresu dotkliwości. W naszym algorytmie, wartość dolnej granicy nigdy nie będzie mniejsza niż zero z uwagi na fakt, że rejestrujemy tylko straty, a nie przychody. Niech i -ty scenariusz będzie z zakresu dotkliwości $[a_i, b_i]$ i częstości k_i , a scenariusz j -ty będzie z zakresu dotkliwości $[a_j, b_j]$ i częstości k_j , gdzie $i < j$.

Zdefiniujmy $r_{ii} = 1$ dla $1 \leq i \leq r$

Dla $1 \leq i < j \leq r$ mamy

$$r_{ij} = \begin{cases} \frac{b_i - a_j}{b_i - a_i} & \text{gdy } j - \text{ty scenariusz pokrywa częściowo } i - \text{ty scenariusz} \\ 0 & \text{w przeciwnym przypadku} \end{cases}$$

oraz $r_{ij} = 0$ dla $i \geq j$

Oznaczmy przez $K = (k_i)_{1 \leq i \leq r}$ wektor skumulowanych częstości F scenariuszy, wówczas korekta będzie postaci:

$$\hat{K}orekta(F_i)_{1 \leq i \leq r} = R \cdot K$$

Należy zauważyć, że estymator $\hat{K}orekta$ realizuje rozliczenie skumulowanych częstotliwości z uwzględnieniem pokrywania się obszarów dotkliwości wydarzeń podanych w scenariuszach. Dla każdego scenariusza s_i , gdzie przedział $[a_i, b_i]$ określa zakres dotkliwości, a F_i określa skumulowaną (narastającą), wartość prawdopodobieństwa wystąpienia wydarzenia związanego z tym scenariuszem w próbie $l = \sum_{i=1}^T n_i$ obserwacji. Podobnie jak w przypadku jednego scenariusza, trzeba znaleźć F_i zdarzeń występujących w każdym scenariuszu spośród l obserwacji. Jeśli znajdziemy mniej niż F_i wydarzeń, to musimy poszerzyć zbiór dotkliwości poprzez doładowanie różnicy z odpowiedniego rozkładu.

Tworzymy zbiór $S = \{G_l^\psi(x) \mid l\}$ dla różnych losowań o liczebności l i rozkładzie równym funkcji splotu $F_{\lambda(n)}^*$. Rozmiar S jest zazwyczaj rzędu 100 000. Dla każdego $G_l^\psi(x)$ w S możemy wyznaczyć poziom ufności (np. 99,9%) metodą Monte Carlo, otrzymany przy użyciu $G_l^\psi(x)$ jako rozkładu dotkliwości oraz $\lambda(n)$ jako rozkładu częstotliwości (Brunner 2009).

Chociaż używamy wewnętrznych danych w celu estymacji rozkładu częstotliwości, to nowy rozkład częstotliwości może się zmienić. W naszej metodologii zakładamy, mały udział liczby symulacji danych scenariuszowych w stosunku do liczby danych historycznych, średnia wartość częstotliwości

nie powinna ulec zmianie. Jeśli średnia wartość ulegnie jednak zmianie, musimy przeliczyć rozkład częstości. W przypadku modelu Poissona, jako rozkładu częstości, taka korekta jest trywialna. Skorygowany parametr Poissona będzie równy: $\frac{l + \text{liczba losowań dla scenariuszy połączonych}}{T}$.

Zamiast metody Monte Carlo (MC) można do obliczenia splotu zastosować formuły aproksymacyjne lecz w praktyce jest to metoda bardzo rzadko stosowana, gdyż znacznie trudniej pozwala na pełną automatyzację procesu z uwagi na konieczność stosowania zaawansowanego aparatu analitycznego. W ryzyku kredytowym, ze względu czasy przetwarzania dużych wolumenów portfeli wykluczające możliwość stosowania metod symulacyjnych stosuje się rozwiązania analityczne (np. w metodologii CR+), gdzie rodziny rozkładów oparte są na rozkładach Poissona i Gamma, a i tak proste metody rekurencyjne prowadzą do poważnych błędów wynikających z zaokrągleń. Trzeba więc stosować poprawki oparte na aproksymacji punktów siodłowych. Dokładność uzyskiwana w obliczeniach ryzyka operacyjnego metodą MC przy rozmiarze rzędu 100 000 jest wystarczająca .

W metodologii opisanej powyżej nie został uwzględniony fakt powolnych zmian w środowisku wewnętrznym i zewnętrznym banku. Zmiany takie są rejestrowane np. przy pomocy wskaźników KRI. Uwzględnienie tego czynnika wykracza poza zakres tej pracy.

8. Metoda zbiorów rozmytych

W niniejszym rozdziale przedstawione zostaną podstawowe koncepcje wykorzystania zbiorów rozmytych do procesu samooceny w ryzyku operacyjnym. System oceny ryzyka oparty został na materiałach dotyczących doświadczeń lotniczych opisanych w systemie FORAS (Xua 2003).

8.1. Wprowadzenie

System ekspercki jest zbiorem faktów, reprezentujących merytoryczną wiedzę ekspertów (Dym i Levitt, 1991; Kandel, 1992). Ich wiedza jest wyrażana, jako zbiór reguł wnioskowania w następującej formie:

Jeśli **poprzednik** to **następnik**.

Zdanie „poprzednik” jest właściwie testem i może mieć formę wyrażenia utworzonego z wyrażeń logicznych, które posiadają określoną wartość: Prawda lub Fałsz. Zazwyczaj, klauzule poprzedzające są zapisywane jako zdanie złożone składające się z kilku wyrażeń. Reguła, której poprzednik jest w innej formie może być przepisana na powyższy schemat (Andrews, 1986).

Jeśli zdanie „poprzednik” ma wartość True, to możemy powiedzieć, że zdanie jest aktywne. W procesie przetwarzania reguły mogą ujawnić się fakty, których konsekwencje mogą spowodować dodatkowe aktywowanie innych zdań.

Metodologia stosowania zbiorów rozmytych składa się z dwóch części: rozwój modelu oraz szacownie ryzyka. W procesie rozwoju tworzony jest model przy użyciu domen wiedzy opartych na dostępnych wewnętrznych bazach danych. Proces szacowania ryzyka polega na wprowadzeniu danych operacyjnych dotyczących lotu do modelu i obliczeniu wartości współczynnika ryzyka.

Metodologia FORAS opiera się na pięciu zasadach:

1. Podstawą modelu ryzyka jest prewencja i identyfikacja prekursorów zdarzeń. Poprzez skupienie się na procesie i prekursorach, wskaźnik ryzyka uwzględnia te zmienne, które towarzyszą niebezpiecznym sytuacjom. Wczesne zidentyfikowanie tych zmiennych prowadzi do podniesienia poziomu ryzyka, oraz potencjalnego przeciwdziałaniu.
2. Modele ryzyka oparte są na ludzkiej wiedzy. Są one tworzone na bazie zbiorowej wiedzy ekspertów merytorycznych i ich rozumieniu podstawowych procesów, które mogą prowadzić do wypadków lub incydentów. Wiedza ta może wynikać z poszczególnych działań i procedur organizacji, jak również ogólnej wiedzy teoretycznej lub empirycznych badań (takie jak zmęczenie wpływ na ludzkie działania).
3. Analiza ryzyka w modelu musi być szybka, spójna, niezależna od indywidualnego nastawienia użytkownika programu. Obliczany jest indeks wielowymiarowy reprezentujący „poprzedniki” ryzyka wskazane przez ekspertów. Jeżeli dane, są dostępne w „czasie rzeczywistym”, to wskaźnik ryzyka również dostępny jest na bieżąco. Ponadto, analiza tych samych danych

zawsze daje taki sam współczynnik ryzyka, w odróżnieniu od opinii różnych subiektywnych podmiotów.


4. Ocena ryzyka musi być ilościowa, dzięki czemu możliwe są porównania i wykorzystanie jej do celów związanych z przetwarzaniem ilościowym. Wartość indeksu ryzyka obliczana na podstawie modelu reprezentujący względne ryzyko dla określonej kategorii zdarzeń. Indeks jest wyrażony w skali od 0 do 1. Liczba ta stanowi oszacowanie ryzyka szczególnego poprzez rozważenie czynników mogących mieć wpływ zarówno na wystąpienie jak i zapobieżenie stracie. Nie jest to prawdopodobieństwo, ale raczej wskaźnik intensywności w stosunku do wartości wyjściowej lub do innych zdarzeń. Większa wartość oznacza większe prawdopodobieństwo zdarzenia. Taki ilościowy względny wskaźnik umożliwia porównywanie zdarzeń i ułatwia komunikację w kwestii ryzyka w całej organizacji.
5. Analizy muszą być przydatne do wyliczania ryzyka na wszystkich poziomach organizacji czyli ilościowa ocena ryzyka, musi być spójna i obiektywna. Proces musi systematyzować opis ludzkiego doświadczenia, zapewniać naturalną reprezentację wiedzy w systemie eksperckim, i automatyzować proces oceny ryzyka. Model taki może zostać zapewniony poprzez ilościowy współczynnik ryzyka reprezentujący oszacowanie probabilistyczne zagrożenia.

8.2. Reprezentacja ryzyka


Model oceny ryzyka jest opisywany przez zespół czynników przyczynowych, które są związane z ryzykiem. Niektóre schematy budowy modelu obejmują listy kontrolne, diagramy przyczynowo skutkowe, drzewa decyzyjne oraz rozkłady hierarchiczne (np. FORAS) w (Hadjimichael 2009). Przyczynowymi czynnikami są zwykle mierzalne zmienne, a struktura procesowa (czasami organizacyjna) stanowi model obliczeniowy dla oceny i kwantyfikacji ryzyka.

Hierarchiczna dekompozycja

System FORAS stanowi strukturę koncepcyjną hierarchii czynników ryzyka. W tej reprezentacji, prezentowane są kategorie ryzyka. „Podejście do Lądowania i Ryzyko Wypadku samolotu”, znajduje się w górnym węźle hierarchicznego drzewa, pod nim znajdują się kategorie złożone tzw. terminy wysokiego poziomu, takie jak np. funkcjonalność załogi. Wprowadzone są również terminy niskiego poziomu takie jak np. długość okresu pracy. Terminy niskiego poziomu znajdują się w dolnej, części hierarchii.



Rysunek 57. Najwyższy szczebel struktury Ryzyka Podejścia do Lądowania i Ryzyka Wypadku przy Lądowaniu. Źródło: (Hadjimichael 2009).



Rysunek 58. Fragment struktury ryzyka Niskiego Poziomu. Źródło (Hadjimichael 2009).

Hierarchiczna struktura ryzyka pokazuje, jak poszczególne ryzyka rozkładają się na części składowe. Hierarchia jest reprezentowana przez matematyczny obiekt znany jako drzewo. W takim przedstawieniu hierarchii, każdy czynnik jest reprezentowany przez węzeł. Czynniki poniżej danego węzła i połączone do niego nazywamy następnikami, wyznaczają one strukturę tego czynnika i określane są jako węzły podrzędne. Węzły położone najniżej nazywane są liśćmi. Węzeł nad danym węzłem reprezentuje jego nadrzędną kategorię. Węzeł na szczycie drzewa dekompozycji nazywa się węzłem głównym. Biorąc pod uwagę długość drogi pomiędzy węzłami, a w szczególności węzłem X a węzłem głównym, możemy określić głębokość węzła X.

Zbiór zasad wiąże się z każdym węzłem i jego następnikami. Zasady te stanowią relacje i jednocześnie wyznaczają moc relacji między czynnikami ryzyka. Wskazują one, w jaki sposób czynnik typu następnik wpływa na czynnik nadrzędny, a więc w jaki sposób można obliczyć wartość czynnika ryzyka nadrzędnego używając wartości jego czynników następujących. Węzły podrzędne reprezentują zmienne poprzedzających ją reguł, podczas gdy węzeł nadrzędny odpowiada zmiennej typu konsekwencji.

Oznaczamy zbiór reguł, jako sekwencję tabel. Dla zasady określonej przez dwie wejściowe zmienne, A_1 (m możliwych wartości $v_{1,1}, \dots, v_{1,m}$) oraz A_2 (n możliwych wartości $v_{2,1}, \dots, v_{2,n}$), zbiór możliwych wartości nadrzędnej zmiennej R jest reprezentowany przez tabelę $T_{m \times n}$. Dla reguły $A_1=v_{1i}$ oraz $A_2=v_{2,j}$ reguła nadrzędna oznaczona jest przez $R = T_{i,j}$. Zestawy reguł dwu-zmiennych są reprezentowane przez jedną tabelę $T_{m \times n}$. Trój-zmienne reguły (gdzie A_3 ma l możliwych wartości) są reprezentowane

przez 1 tabel o wymiarach $m \times n$. Taki zapis tabelaryczny jest łatwo zrozumiały przez ekspertów w danej dziedzinie, co bardzo ułatwia przypisywanie wartości wyjściowych dla każdej kombinacji wejściowych zmiennych.

Tabela „Przepracowanego czasu” zależna od dwóch czynników: „Pory dnia” i „Stanu dyżurów”.

		Pora dnia		
		Niskie	Średnie	Wysokie
Stan dyżurów	Niskie	1	4	6
	Średnie	2	8	12
	Wysokie	4	16	24


Tabela 26. Przykładowe reguły definiujące Ryzyko Przepracowanego Czasu. Źródło (Hadjimichael 2009).

Rysunek demonstruje zestaw reguł opisujących ilość pracy, w skład, których wchodzi dziewięć zasad pogrupowanych w dwie zmienne: A_1 - czas pracy i A_2 natężenie pracy. Zmienne poprzedzające mogą mieć następujące możliwe wartości: niskie, średnie i wysokie. Wartości te zostały wybrane przez ekspertów, na podstawie ich wiedzy na dany temat. Na przykład, wartość niska dla zmiennej A_2 opisuje sytuację, gdy pilot spędził małą liczbę godzin w powietrzu i jest oceniana w kontekście ryzyka ilości pracy. Zmienna konsekwencji R ma wartość z zakresu 1-24 (24 reprezentuje największe ryzyko związane z obciążeniem pracą). W typowym zestawie reguł lewy górny róg tabeli („stan dyżurów” = niski, „pora dnia” = niska) oznacza zasadę:

Jeśli stan dyżurów ma wartość „niska” i liczba godzin pracy jest „niska” wówczas ryzyko związane z obciążeniem pracą ma wartość 1

W praktyce każdy podział węzła jest ograniczony do co najwyżej trzech czynników, w celu ograniczenia liczby reguł dla tego węzła, a tym samym złożoności procesu aktywizacji wiedzy. Zakładając, maksymalnie trzy wartości na jeden czynnik, otrzymujemy tabelę reguł (27 zasad).


Aby zminimalizować złożoność, trzeba założyć maksymalną liczbę węzłów przekształcających, bardziej skomplikowane relacje wymagają węzła pośredniego, jak na rysunku poniżej. Pośredni węzeł jest semantyczną zmienną, która może być uznana za "zmienną wyższego poziomu" w stosunku do dwóch węzłów potomnych



Rysunek 59. Przykładowa struktura z węzłem pośrednim. Źródło (Hadjimichael 2009).


8.3. Reprezentacja ryzyka przez rozmyty system ekspertowy

Eksperci merytoryczni wybierają możliwe wartości dla każdego z czynników ryzyka przypisując im zmienne lingwistyczne oraz zapewniają odpowiednie definicje rozmytych wartości, takich jak: niski, średni i wysoki zdefiniowane na odpowiednim uniwersum. Uniwersum zmiennych dla węzła typu liść jest określona przez semantycznego znaczenia zmiennej i rozsądnym zakresie możliwych wejść. Na przykład, rozsądny wybór godzin dotyczących obciążenia dziennego może być 0-12. Rysunek poniżej przedstawia funkcję przynależności dla wartości godzin służby.



Rysunek 60. Funkcje przynależności dla czynnika DYŻURY . Źródło (Hadjimichael 2009).

Zakres zmiennej wyjściowej 1-12 został wybrany przez ekspertów, jako najbardziej odpowiedni do oceny zestawu reguł. Każda z tych liczb jest reprezentowana przez zbiór rozmyty, funkcja członkostwa ma postać np. funkcji trójkątnej jak na rysunku poniżej (Dubois i Prade, 1988).




Rysunek 61. Funkcje przynależności dla liczb rozmytych {2, 4, 6, 8, 10, 12}. Źródło (Hadjimichael 2009).

Tak więc, dla wszystkich węzłów nie-liści uniwersum dla reprezentowanych zmiennych jest zbiorem liczb rzeczywistych między 1 a 13. Oczywiście, eksperci z danej dziedziny mogą swobodnie wybrać dowolny zakres wartości wyjściowych dla reguły. Dla wybranego zakresu zbiory rozmyte są definiowane w tym zakresie, aby można było stosować je w łańcuchowym procesie, gdy wartość wyjściowej zmiennej jest używana, wyżej w hierarchii.

8.4. Analiza i wnioskowanie

Ogólne ryzyko oblicza się stosując reguły wnioskowania w łańcuchowym procesie, w kolejności oznaczonej przez hierarchię ryzyka. Węzły są oceniane w kolejności według ich głębokość w strukturze drzewa. Tak więc, wszystkie węzły na głębokości „i” są oceniane przed oceną węzłów na głębokości „i-1”. Taka kolejność zapewnia, że wszystkie niezbędne dane wejściowe są dostępne dla każdego węzła obliczeń. Węzły na równej głębokości mogą być oceniane w dowolnej kolejności.

Struktura wnioskowania wyrażona w postaci drzewa.



Rysunek 62. Przykładowe drzewo decyzyjne. Źródło (Hadjimichael 2009).

Wartości dla czynników ryzyka będących liśćmi są przepisywane bezpośrednio z baz danych dla zmiennych wejściowych określonych przez te czynniki ryzyka. Listy dotyczące załogi są pobierane z bazy danych i wykorzystywane do obliczania wartości początkowych. Z nich obliczana jest funkcja przynależności dla rozmytych wartości węzła nadrzędnego.

Rozmyte wartości ryzyka jest obliczany dla każdego węzła bez liści najpierw obliczania wartości jego węzłów następujących, a następnie ocena reguły dla tego węzła. Wartości węzłów następujących są na ogół „ostrą” wartością, gdy węzeł następujący jest węzłem liścia lub rozmytą wartością przynależności, gdy węzeł dziecko nie jest liściem.

Na każdym poziomie drzewa obliczana jest ilościowa miara ryzyka, którą można przetłumaczyć na interpretację biznesową. Metodologia przypisywania wag poszczególnym węzłom procesu leży poza zakresem niniejszej pracy.

tylko na podstawie wyników uzyskanych podczas warsztatów samooceny. Metody integracji wyników z różnych źródeł leżą poza tematem niniejszej pracy.

9.2. Scenariusze i kwestionariusze

Ocena narażenia na ryzyko przeprowadzana była z wykorzystaniem kwestionariuszy zbudowanych przy użyciu wcześniej zdefiniowanych miar, skali odpowiedzi, pytań i grup pytań. Proces oceny i walidacji wyników oraz ich analiza zorganizowane były w postaci „workflow”.

Scenariusze umożliwiły ocenę potencjalnych skutków przewidywanych zdarzeń operacyjnych i ich wpływu na ryzyko operacyjne. W ramach oceny scenariuszowej do ekspertów trafiły poszczególne scenariusze, z prośbą o wskazanie spodziewanego poziomu określonej miary ryzyka. Oceny polegały na określeniu spodziewanej częstości zdarzeń dla zadanego przedziału wartości straty, a w przypadku scenariusza opisującego zdarzenia sporadyczne wartości straty minimalnej, maksymalnej oraz częstości zdarzeń.

Uzyskane wyniki miały służyć przeprowadzaniu analiz statystycznych oraz przygotowywaniu lepszych mechanizmów kontrolnych zapobiegających materializacji ryzyk.

9.3. Ocena jakościowa ryzyka operacyjnego dla aplikacji IT

Ocena jakościowa dotyczy przede wszystkim określeniu istotności danego punktu występowania ryzyka. W bieżącym przykładzie nie była brana pod uwagę.

lp	Pytanie	Jednostka miary	Odpowiedź	Liczba punktów
1	2	3	4	5
1	Jaki jest maksymalny, dopuszczalny czas przywrócenia działania aplikacji?	[godz]		1-10
2	Czy aplikacja działa wyłącznie w ramach sieci lokalnej?	tak/nie		5 / 0
3	Jaka jest całkowita liczba użytkowników aplikacji?	liczba		1-10
4	Czy aplikacje służą do przeprowadzania lub rozliczania transakcji z klientami Banku?	tak/nie		10 / 0
5	Czy aplikacja służy do sporządzania sprawozdawczości obowiązkowej?	tak/nie		10 / 0
6	Czy za pomocą aplikacji dokonuje się transakcji finansowych?	tak/nie		10 / 0
Współczynnik istotności aplikacji				$\frac{\sum pkt.}{55} 100\%$

Tabela 27. Przykładowy kwestionariusz do zbierania danych jakościowych. Źródło opracowanie własne

9.4. Ocena ilościowa ryzyka operacyjnego dla aplikacji IT

Szacunki ilościowe zbierane w trakcie samooceny to:

- Oczekiwana wielkość strat w ciągu roku
- Strata oczekiwana,
- Straty najgorszego roku (tzw. „rozsądna strata maksymalna”) w zadanym horyzoncie czasowym,
- Czasy oczekiwania na straty przekraczające graniczną wartość.

Poniżej znajduje się fragment kwestionariusza szczegółowego do zbierania opinii. Do obliczeń wykorzystane zostały zagregowane informacje uzyskane na podstawie tego kwestionariusza.

Ip.	Zagrożenia, na które może być narażona aplikacja	Zastosowane instrumenty zabezpieczające	Rodzaje skutków finansowych zdarzeń operacyjnych	Ile razy zdarzenie może wystąpić w ciągu roku	Jakie ŚREDNIE skutki finansowe może spowodować zdarzenie [PLN]	Jak często występuje maksymalna strata Raz na x lat	Jakie maksymalne skutki finansowe może spowodować zdarzenie [PLN]	Czas do zdarzenia o skutkach równych lub powyżej podanej kwoty [PLN]			
				Liczba/ułamek				lat	lat	lat	lat
1	2	3	4	5	6	7	8	9	10	11	12
	Działanie szkodliwego oprogramowania w tym: ataki wirusów, makrowirusów, bomby logiczne, spyware, malware, snifferów, trojanów, rootkit	1. Zainstalowane programy antywirusowe	☐ 1. Koszty związane z usługami firm zewnętrznych polegające na przywróceniu aplikacji do działania	☐							
		2. Bieżąca aktualizacja programów antywirusowych	☐ 2. Straty wynikające z przerwy w działaniu aplikacji lub funkcjonalności aplikacji	☐							
		3. Bieżąca aktualizacja oprogramowania systemowego	☐ 3. Straty wynikające ze skarg klientów	☐							
		4. Regularne skanowanie dysków twardych, na których znajdują się dane	☐ 4. Straty wynikające z błędnego księgowania	☐							
		5. Stosowanie zabezpieczeń fizycznych (firewall)	☐ 5. Inne (.....)	☐							
		6. Ograniczony dostęp do Internetu na serwerze aplikacji									
		7. Regularne tworzenie kopii zapasowych									
		8. Regularne testy odtwarzania aplikacji z kopii zapasowych									
		9. Regularne skanowanie dysków twardych, na których zainstalowana jest aplikacja									
		10. Monitorowanie aplikacji systemem xxxx									
		11. Plan awaryjny									
		1. Regularne testy odtwarzania aplikacji z kopii zapasowych	☐ 1. Koszty lub nakłady związane z koniecznością dokonania zmiany w aplikacji	☐							
		2. Opis kompatybilności aplikacji z oprogramowaniem systemowym i sprzętem	☐ 2. Straty wynikające z błędnego księgowania	☐							
		3. Testowanie aplikacji	☐ 3. Straty wynikające z przerwy w działaniu aplikacji lub funkcjonalności aplikacji	☐							

Tabela 28. Przykładowy kwestionariusz do zbierania danych ilościowych. Źródło opracowanie własne.

9.5. Przeprowadzanie procesu samooceny

Ocena wykonywana była przez ekspertów, którzy otrzymali kwestionariusz. Istotne było, że w systemie funkcjonował jeden zestaw kwestionariuszy przypisany do danego procesu i tylko ten zestaw podlegał przetwarzaniom.

Eksperci udzielali odpowiedzi na kolejne pytania podając szacowane przez siebie wartości zgodnie z określoną dla pytania skalą odpowiedzi. Do zakończenia oceny niezbędnie było udzielenie odpowiedzi na wszystkie pytania. Po zakończeniu oceny wypełniony kwestionariusz przesyłany był do walidacji.

Walidacja wyników procesu samooceny była rozpatrywana na dwu poziomach:

- Poziomie wstępnym przeprowadzanym przez szefów ryzyka operacyjnego związanych z danymi obszarami ryzyka
- Poziomie analitycznym związanym z analizą wpływu wyników uzyskiwanych w procesie samooceny na kalkulacje VaR.

Obok wyników ilościowych w trakcie walidacji brane były pod uwagę również oceny jakościowe. Strategia oceny jakości odpowiedzi polegała na zastosowaniu analizy procentowej w postaci przygotowanych algorytmów, przeanalizowaniu wyników, a następnie zastosowaniu ich do oceny wyników ilościowych.

9.6. Dane źródłowe i wyniki analiz

Jako dane wejściowe do modelowania użyte zostały wyniki uzyskane od ekspertów jednego z dużych banków polskich w trakcie warsztatów. W trakcie sesji warsztatowej zadawane pytania dotyczyły prawdopodobieństwa i wielkości strat poszczególnych procesów. Z uwagi na poufność danych zaprezentuję jedynie te wartości liczbowe, które posłużyły do kwantyfikacji ryzyka bez odwoływania się do szczegółów umożliwiających identyfikację banku.

Do kalibracji trzech parametrów potrzebne były różne punkty wartościowe oceniane przez ekspertów. Do oceny ryzyka procesu „lp=1” wzięto wyniki z poniższej tabeli:

lp.	Ile razy zdarzenie może wystąpić w ciągu roku	Jakie skutki finansowe może spowodować jedno zdarzenie	Jakie ŚREDNIE skutki finansowe może spowodować zdarzenie	Jak często występuje maksymalna strata	Jakie maksymalne (rozsądne) skutki finansowe może spowodować zdarzenie	Czas do zdarzenia o skutkach równych lub powyżej podanej kwoty [XXXPLN]		
						5000	10000	20000
	liczba	[XXXPLN]	[XXXPLN]	raz na x lat	[XXXPLN]	lata	lata	lata
1	6	7	8	9	10	11	12	13
1.	2	1 000	1 100	25	10 000	10	20	100

Tabela 29. Dane uzyskane w wyniku procesu samooceny. Źródło opracowanie własne.

Proces oznaczony symbolem „1” dawał przeciętne straty w wysokości 1 000 XXXPLN dwa razy w ciągu roku natomiast raz na 25 lat powodował stratę 10 000 XXXPLN.

Trudno było oszacować dokładność uzyskanych wyników ponieważ dane zbierane były pierwszy raz i większą uwagę poświęcono dokumentowaniu procedury. Bezpośrednie pytania o parametr, pozwalający szacować błąd oceny (mało intuicyjny), nie zostało odnotowane, ponieważ wszyscy eksperci ostrożnie oceniali swoje błędy na $\pm 10\%$.

Do budowy modelu strat na podstawie danych zebranych od ekspertów wybrane zostały dwa rozkłady parametryczne: jeden do modelowania częstości i jeden do modelowania dotkliwości. Taka metodologia zgodna z metodą LDA (Loss Distribution Approach) ma swoje uzasadnienie w praktykach aktuarialnych (Brunner 2009).

Jako model analityczny został wykorzystany model „typu duration”. Został on jednak zmodyfikowany pod kątem zwiększenia dokładności oraz użycia intuicyjnych mapowań opinii ekspertów na dane do kalibracji modelu.

W modelu duration mamy, średnią wartość czasu d pomiędzy dwoma zdarzeniami:

$$E(d) = \frac{1}{\lambda(1 - F_{\theta}(X))}$$

Gdzie θ oznacza wszystkie parametry rozkładu dotkliwości.

Przejdźmy teraz do procedury kalibracji (estymacji) parametrów obu rozkładów: częstości i dotkliwości. Tradycyjnie do kalibracji proponowane jest użycie par wartości: (czas, próg) czyli informacji jak często może zajść zdarzenie o dotkliwości powyżej progowej wartości (Jobst 2007).

W artykule (Frachot 2001) zaproponowana została procedura wielokrotnego pytania ekspertów o orientacyjny czas pomiędzy zdarzeniami dla różnych progów. Liczba progów powinna przekraczać liczbę szacowanych parametrów.

Na podstawie danych o odległościach czasowych oraz wartościach strat (d_j, X_j) uzyskanych od ekspertów można kalibrację przeprowadzić przy użyciu zwykłej metody najmniejszych kwadratów, jednak z uwagi na to, że rozkład (d_j) jest rozkładem Poissona lepiej jest użyć wag w_j . Jako wagi możemy wybrać wartości związane z oczekiwaną wariancją – dla najczęściej używanych rozkładów będą to funkcje wartości oczekiwanych $E(d_j)$:

$$(\lambda, \theta) = \min_{\lambda, \theta} \sum_{j=1}^p w_j \left(d_j - \frac{1}{\lambda(1 - F_{\theta}(X_j))} \right)^2$$

Poniżej przedstawiony został nieco zmodyfikowany algorytm. Dotkliwość straty powinna być modelowana dwoma parametrycznymi rozkładami. Jedna rodzina rozkładów będzie używana do analizy zdarzeń „typowych” (body of distribution) czyli występujących stosunkowo często, druga rodzina do zdarzeń „rzadkich” (tail of distribution). Informacje uzyskane od ekspertów powinny zostać przełożone na parametry tych rozkładów (Ergashev 2009).

Jako rodzinę dla zdarzeń „typowych” wybrano 2-parametryczny rozkład log-normalny:

Funkcje gęstości i dystrybuanty:

$$f_{log-normal}(x; \mu, \sigma) = \frac{1}{x\sigma\sqrt{2\pi}} \exp\left(-\frac{(\ln x - \mu)^2}{2\sigma^2}\right)$$

$$F_{log-normal}(x; \mu, \sigma) = \Phi\left(\frac{\ln x - \mu}{\sigma}\right)$$

Dwa pierwsze momenty: $E_{log-normal}(x) = \exp\left(\mu + \frac{\sigma^2}{2}\right)$

$$Var_{log-normal}(x) = (e^{\sigma^2} - 1)\exp(2\mu + \sigma^2)$$

Jako rodzinę dla zdarzeń „rzadkich” wybrany został 2-parametryczny rozkład Uogólniony Rozkład Pareto (GDP) (Buch-Kromann 2009):

Funkcje gęstości i dystrybuanty:

$$f_{GDP}(x) = \begin{cases} \frac{1}{\beta} \left(1 + \xi \frac{(x - limit)}{\beta}\right)^{-1-1/\xi} & \xi \neq 0 \\ \frac{1}{\beta} \exp\left(-\frac{(x - limit)}{\beta}\right) & \xi = 0 \end{cases}$$

$$F_{GDP}(x) = \begin{cases} 1 - \left(1 + \frac{\xi(x - limit)}{\beta}\right)^{-1/\xi} & \xi \neq 0 \\ 1 - \exp\left(-\frac{(x - limit)}{\beta}\right) & \xi = 0 \end{cases}$$

Dwa pierwsze momenty: $E_{GDP}(x) = \mu + \frac{\sigma}{1-\xi}$ dla $\xi < 1$

$$Var_{GDP}(x) = \frac{\sigma^2}{(1-\xi)^2(1-2\xi)} \quad \text{dla } \xi < 0.5$$

Powszechnie przyjmowane będzie założenie, że wartości „typowe” to wartości, gdy (strata $\leq$ LIMIT) natomiast wartości „rzadkie” to takie, gdy (strata $\geq$ LIMIT).

Do estymacji parametrów rozkładu log-normalnego przyjęto następujące założenia na podstawie tabeli

lp.	Ile razy zdarzenie może wystąpić w ciągu roku	Jakie skutki finansowe może spowodować jedno zdarzenie	Jakie ŚREDNIE skutki finansowe może spowodować zdarzenie	Jak często występuje maksymalna strata	Jakie maksymalne (rozsądne) skutki finansowe może spowodować zdarzenie
	liczba	liczba	[XXXPLN]	raz na x lat	[XXXPLN]
1.	6	7	8	9	10
1.	2	1,000	1,100	25	10,000

Tabela 30. Fragment tabeli z danymi samooceny. Źródło opracowanie własne.

- 1 Średnia wartość straty „typowej” wynosi 1 100 (XXXPLN)
- 2 Limit czyli granica typowych zdarzeń wynosi 10 000 (XXXPLN) i jest osiągnięta raz na 25 lat

Na tej podstawie można oszacować parametry rozkładu log-normalnego oraz parametr λ dla procesu Poissona częstości:

	Parametr	Wartość
1	lambda	6.410441
2	sigma	1.146666


Tabela 31. Tabel z wynikami parametrów. Źródło opracowanie własne.

Jako parametr μ do rozkładu log normalnego przyjęta została wartość:

$$\log(E(\text{strata typowa})) - \sigma^2/2.$$

Na podstawie danych uzyskano wartość $\mu = 6.3532$.

Wynik modelu rozkładu „typowej straty” można przedstawić na poniższym wykresie



Rysunek 64. Wykres gęstości dla „typowej” straty omawianego przykładu. Źródło opracowanie własne.

Do estymacji parametrów rozkładu Uogólnionego Pareto na podstawie tabeli

lp.	Jakie maksymalne (rozsądne) skutki finansowe może spowodować zdarzenie [XXXPLN]	Czas do zdarzenia o skutkach równych lub powyżej podanej kwoty [XXXPLN]		
		5000	10000	20000
		lat	lat	lat
1	8	9	10	11
1.	10 000	10	20	100

Tabela 32. Fragment tabeli z danymi samooceny. Źródło opracowanie własne.

Przyjęto następujące założenia:

1. Wartość LIMITU czyli granicy powyżej której stosowany będzie rozkład GPD (Uogólniony Pareto) została przeliczona na 97%-centyl rozkładu log-normalnego uzyskanego dla „typowych „ zdarzeń, wartość ta wyniosła 4 919 XXXPLNek. Jako procentowy próg wybrano 97% na podstawie doświadczeń w kilku przed-wstępnych oszacowaniach z udziałem ekspertów.
2. Wybrano trzy progi wartości {5 000, 10 000, 20 000}, dla których zostały ocenione wartości „duration” – {10, 20, 100}

Parametry rozkładów obliczane były w wyniku znalezienia minimum sumy kwadratów poniższego wyrażenia:


$$(\lambda, \theta) = \min_{\lambda, \theta} \sum_{j=1}^3 \frac{1}{(\text{duration}_j)^2} \left(\text{duration}_j - \frac{1}{\lambda (1 - F_{GDP\theta}(\text{Próg}_j))} \right)^2$$

Na tej podstawie można oszacować parametry rozkładu GDP oraz parametr λ dla procesu Poissona częstości:


	Parametr	Wartość
1	lambda	3.351953
2	beta	7557.533609
3	eps	-0.130946

Tabela 33. Tabel z wynikami parametrów. Źródło opracowanie własne.

Na podstawie wartości dla obu rozkładów uzyskano następujące wykresy obrazujące zależność skumulowanego prawdopodobieństwa wystąpienia danej straty:



Rysunek 65. Wykres dystrybuanty rozkładu Log-normal / GPD uzyskanego na danych z przykładu. Źródło opracowanie własne.



Rysunek 66. Wykres wysokich percentyli dystrybuanty rozkładu Log-normal / GPD uzyskanego na danych z przykładu. Źródło opracowanie własne.

Dla celów praktycznych przebadano stabilność powyższego modelu. W tym celu model został zbudowany w oparciu o „zaburzone” odpowiedzi ekspertów. Dzięki temu można sprawdzić zmiany w uzyskanych wynikach. Aby przybliżyć wyniki na podstawie uzyskanego modelu przeliczona została wartość kapitału ekonomicznego VaR i stabilność została przeliczona dla tej wartości. Zaburzenia zostały pomyślane jako „duże zaburzenia” ponieważ opinie ekspertów nie były dokładne.

W wersji tabelarycznej wartości zagrożone VaR dla różnych poziomów ufności wynoszą:

VaR [XXXPLN] Poziom ufn. 95%	VaR [XXXPLN] Poziom ufn. 99.0%	VaR [XXXPLN] Poziom ufn. 99.5%	VaR [XXXPLN] Poziom ufn. 99.9%
13,158.75	24,283.20	28,552.45	37,585.40

Tabela 34. Wartości VaR dla różnych poziomów ufności uzyskane na podstawie danych z przykładu. Źródło opracowanie własne.


Obliczenia sprawdzające stabilność modelu Duration

Do obliczeń stabilności użyto następujących wartości „zaburzonych”:

Ip.	Jakie maksymalne (rozsądne) skutki finansowe może spowodować zdarzenie [XXXPLN]	Czas do zdarzenia o skutkach równych lub powyżej podanej kwoty [XXXPLN]		
		5 000 lat	10 000 lat	20 000 lat
1	8	9	10	11
Wariant 1	10 000	10	20	50
Wariant 2	10 000	10	30	100
Wariant 3	10 000	10	40	200

Tabela 35. „Zaburzone” dane samooceny użyte do badania stabilności modelu. Źródło opracowanie własne.

Wyniki uzyskane z modeli zaburzonych można przedstawić w postaci graficznej oraz tabelarycznej.



Rysunek 67. Wartości dystrybucyj zagregowanej straty dla okresu 1 roku dla różnych wersji „zaburzenia”. Źródło opracowanie własne.

Samoocena	VaR [XXXPLN] Poziom ufn. 95%	VaR [XXXPLN] Poziom ufn. 99.0%	VaR [XXXPLN] Poziom ufn. 99.5%	VaR [XXXPLN] Poziom ufn. 99.9%
Wariant 1	12,817.06	35,006.92	51,676.94	119,249.49
Wariant 2	10,937.02	23,867.08	33,213.32	73,910.69
Wariant 3	10,352.33	18,986.51	24,050.82	41,882.90

Tabela 36. Wartości VaR dla różnych poziomów ufności uzyskane na podstawie różnych wersji „zaburzenia” dla modelu Log-normal/GPD. Źródło opracowanie własne.

Kontrolę poprawności uzyskanych wyników można przeprowadzić jedynie w oparciu o jakościowe argumenty ponieważ bank nie dysponował odpowiednią bazą danych historycznych. Porównanie wartości ryzyka nie może być oparte na monotonicznej zależności „im mniej tym lepiej”.

Jak widać różnice między wersjami są jak czynnik 1 do 3. Z punktu widzenia biznesowego te różnice są bardzo interesujące, tym bardziej, że „zaburzenia” są naprawdę istotne.

Porównując wyniki warto pamiętać, że nadzór „karze” banki za używanie złych modeli koniecznością podniesienia poziomu rezerw, a co za tym idzie kosztów ryzyka, tego samego rzędu (od 2 do 4 razy).

Porównanie wyników dla modelu „tradycyjnego” opartego na rozkładzie log-normalnym.

Dla porównania przeprowadzona została analiza „tradycyjna” tzn. do obliczeń wykorzystana została rodzina rozkładów log-normalnych. Miało to na celu kontrolę wartości korekty wprowadzanej przez użycie rozkładów hybrydowych. Poniżej tabela z wynikami:

Samoocena	VaR [XXXPLN] Poziom ufn. 95%	VaR [XXXPLN] Poziom ufn. 99.0%	VaR [XXXPLN] Poziom ufn. 99.5%	VaR [XXXPLN] Poziom ufn. 99.9%
Wariant 1	17,983.41	32,162.03	40,249.87	66,904.18
Wariant 2	15,853.99	26,140.60	31,690.30	49,623.81
Wariant 3	15,176.88	23,458.15	27,837.53	40,868.75

Tabela 37. Wartości VaR dla różnych poziomów ufności uzyskane na podstawie różnych wersji „zaburzenia” dla modelu log-normal. Źródło opracowanie własne.

Widać stosunkowo małe wartości różnic VaR (czyli percentyli) uzyskane dla różnych wariantów.

Wynik uzyskane dla różnych wariantów mają mały rozrzut co wydaje się mało wiarygodne, gdyż zaburzenia są rzeczywiście bardzo duże. Świadczy to na korzyść modelu hybrydowego.

9.7. Obliczenia dla modelu Supra-Bayes

Przeprowadzone zostały też wstępne obliczenia w oparciu o model Supra-Bayes'a. Model wymaga przygotowania danych w nieco inny sposób. Niestety w trakcie warsztatów nie można było wdrożyć dwu odmiennych metodologii dlatego do obliczeń przyjęte zostały dane ze „sztucznego” scenariusza.

W podejściu Supra-Bayesa mamy oszacowania ekspertów q oraz wstępną specyfikację, którą dokonuje Supra-Bayes, składającą się z: prawdopodobieństwa a`priori p i wektora średnich oszacowań $m=(\mu_1, \dots, \mu_n)$ wektora q . Na tej podstawie Supra-Bayes modyfikuje swoje oszacowanie $p^*(q)$, która jest liniową kombinacją q_s oraz p :

$$p^*(q) = p + \sum_{i=1}^n w_i(q_i - \mu_i)$$

Jeżeli dodatkowo przyjmie się, że wagi w_i są nieujemne, co w sposób naturalny jest wykorzystywane w przypadku zastosowań do ryzyka operacyjnego, muszą być spełnione poniższe nierówności:

$$\max \left\{ \sum_{i=1}^n \frac{w_i \mu_i}{p}, \sum_{i=1}^n \frac{w_i (1 - \mu_i)}{1 - p} \right\} \leq 1$$

Zestaw powyższych warunków pozwala na wyznaczenie wag w_i , choć nie są one wyznaczone jednoznacznie.

Wyniki pokazują, że głównym problemem jest niejednoznaczność wag, która prowadzi do różnych wartości p^* .

Niech dane zebrane podczas warsztatów to opinie indywidualne ekspertów wyglądają następująco:

Ekspert.	Ile razy zdarzenie może wystąpić w ciągu roku	Jakie skutki finansowe może spowodować jedno zdarzenie	Czas do zdarzenia o skutkach równych lub powyżej podanej kwoty [XXXPLN]		
			5000	10000	20000
	Na jeden rok	[XXXPLN]	lata	lata	lata
1	6	7	11	12	13
Supra Bayes	2	1 000	3	5	10
1	1.5	1 000	3	6	10
2	2	1 000	3	5	15
3	3	2 000	1	5	15
4	4	1 500	3	8	10

Tabela 38. „Sztuczny” scenariusz wyniku procesu samooceny. Źródło opracowanie własne.

W tabeli zestawione zostały dane zarówno Supra-Bayes'a (p) jak i opinie ekspertów q .

Poniżej zestawiony został wektor oszacowań m:

Ekspert.	Ile razy zdarzenie może wystąpić w ciągu roku	Jakie skutki finansowe może spowodować jedno zdarzenie	Czas do zdarzenia o skutkach równych lub powyżej podanej kwoty [XXXPLN]		
	Ocenione przez Supra-Bayes'a		Oceniony przez Supra-Bayes'a		
	Na jeden rok		5000	10000	20000
			lata	lata	lata
1	6	7	11	12	13
1	3	1 000	4	6	10
2	3	1 000	5	7	15
3	3	2 000	5	8	15
4	5	2 000	8	10	20

Tabela 39. „Sztuczny” scenariusz wyniku procesu samooceny. Źródło opracowanie własne.

Na podstawie tych danych przeliczony został wektor p oraz p*. Wagi w_i wybrane zostały losowo tak aby spełniony został warunek

$$\max \left\{ \sum_{i=1}^n \frac{w_i \mu_i}{p}, \sum_{i=1}^n \frac{w_i (1 - \mu_i)}{1 - p} \right\} \leq 1$$


Jako optymalne wagi do modyfikacji wektora p wybrano wagi jak najbardziej zbliżone do stałej wartości – tzn. wagi o najmniejszym rozrzucie.

W wyniku uzyskane zostały następujące wyniki:

Zakres strat	Prawdopodobieństwo Supra-Bayes'a p	Prawdopodobieństwo skorygowane Supra-Bayes'a		
		Wektor p* dla wag „optymalnych”	95% Przedział ufności – dolna granica p*	95% Przedział ufności – górna granica p*
Pr(Strata) = [0 - 5,000]	0.8333	0.9435	0.1461	1.0000
Pr(Strata) = [5,000 - 10,000]	0.0667	0.0321	0.0063	0.8630
Pr(Strata) = [10,000 - 20,000]	0.0500	0.0244	0.0041	0.4867
Pr(Strata) = [20,000 - 99999]	0.0500	0.0379	0.0090	0.0402

Tabela 40. Wyniki oszacowań wektora p* w przykładzie metody Supra-Bayes. Źródło opracowanie własne.

Na rysunku poniżej znajduje się wykres z wartościami pierwszej składowej wektora p^* (p_1^*) pokazujący rozrzut wyników:



Rysunek 68. Wyniki wartości p_1^* dla różnych wag w_j w przykładzie metody Supra-Bayes. Źródło opracowanie własne.

Warto zwrócić uwagę, że w powyższym przykładzie wektory q i m różniły się znacznie. Dlatego w drugiej symulacji wektory te wybrane zostały bardzo bliskie sobie (*jeżeli $m \rightarrow q$ to $p \rightarrow p^*$*)

Ekspert.	Ile razy zdarzenie może wystąpić w ciągu roku Ocenione przez Supra-Bayes'a	Jakie skutki finansowe może spowodować jedno zdarzenie [XXXPLN]	Czas do zdarzenia o skutkach równych lub powyżej podanej kwoty [XXXPLN] Oceniony przez Supra-Bayes'a		
			5000	10000	20000
			lata	lata	lata
1	6	7	11	12	13
1	2	1 000	3	6	10
2	2	1 000	3	7	10
3	3	2 000	2	8	15
4	5	2 000	3	10	15

Tabela 41. „Sztuczny” scenariusz wyniku procesu samooceny. Źródło opracowanie własne.

Wyniki poniżej wskazują, że w dalszym ciągu wybór wag w_j ma duży wpływ korektę oszacowań Supra-Bayes'a.

Zakres strat	Prawdopodobieństwo Supra-Bayes'a p	Prawdopodobieństwo skorygowane Supra-Bayes'a		
		Wektor p^* dla wag „optymalnych”	95% Przedział ufności – dolna granica p^*	95% Przedział ufności – górna granica p^*
$\Pr(\text{Strata}) = [0 - 5,000]$	0.8333	0.9165	0.2926	0.9538
$\Pr(\text{Strata}) = [5,000 - 10,000]$	0.0667	0.0104	0.0049	0.5652
$\Pr(\text{Strata}) = [10,000 - 20,000]$	0.0500	0.0247	0.0070	0.3926
$\Pr(\text{Strata}) = [20,000 - 99999]$	0.0500	0.0484	0.0321	0.0556

Tabela 42. Wyniki oszacowań wektora p^* w przykładzie metody Supra-Bayes. Źródło opracowanie własne.

W obu przypadkach widać, że niejednoznaczność szacowania wag ma bardzo istotny wpływ na obliczone prawdopodobieństwo p^* co eliminuje tę metodę z praktycznych zastosowań.

10. Podsumowanie

Celem niniejszej pracy był: a) logiczny projekt modelu bazy danych analitycznych wykorzystywanych do pomiaru ryzyka operacyjnego oraz b) zbadanie nowych metod kalibracji modelu kwantyfikacji wiedzy eksperckiej opartej na algorytmie „duration”.

W rozprawie, w pierwszej części, zaprezentowany został model systemu gromadzenia danych w bazie, zarówno od strony struktur i powiązań tabel zawierających odpowiednie dane, jak i procesów nadzoru i korzystania z bazy. W drugiej części pracy opisany został algorytm transformujący prognozy eksperckie do modelu probabilistycznego pozwalającego kwantyfikować wiedzę ekspercką w postaci odpowiedniego rozkładu prawdopodobieństwa i zaproponowana metoda kalibracji parametrów.

Zadanie pierwsze zostało zrealizowane na podstawie analizy kilku istniejących, komercyjnych systemów informacyjnych używanych w ryzyku operacyjnym oraz analizy potrzeb praktycznych w tej dziedzinie. W oparciu o nie, dostępną literaturę naukową oraz doświadczenie praktyczne opracowany został generyczny model danych umożliwiających analizę i pomiar ryzyka operacyjnego.

Model danych zaprezentowany w niniejszej pracy ma postać Data Martu tzn. składa się z tabel tematycznych powiązanych ze sobą. Struktura tych tabel została zaprojektowana z myślą o systemie wspomagający zarządzanie ryzykiem operacyjnym, który musi spełniać dwie podstawowe funkcje: a) kontrolę procesów i praktyk operacyjnych, b) ilościowy pomiar ryzyka w celu określenia parametrów finansowych wymaganych w procesie zarządzania.

Opracowane zostały struktury poszczególnych tabel pod kątem ich funkcjonowania w systemie oraz procedury pozwalające kontrolować procesy ładowania danych i nadzoru ich wykorzystania w celach biznesowych. W konsekwencji powstał spójny system opisujący proces przetwarzania danych.

Data Mart opisany w niniejszej pracy może służyć jako przewodnik do budowy w banku własnego środowiska. Składa się on z kilku modułów wspierających różne funkcje systemu zarządzania ryzykiem:

- Moduł Danych Wewnętrznych
- Moduł Danych Środowiska Biznesowego KRI
- Moduł Danych Systemu Ubezpieczeń i Monitorowania Działań Zaradczych
- Moduł Danych Samooceny i Scenariuszy

Głównym celem było zbudowanie struktur, które zapewniłyby z jednej strony możliwość kontroli jakości danych ale również pozwalały na zasilenie różnorodnych algorytmów liczenia ryzyka. Zawartość poszczególnych tabel odzwierciedla minimalne wymagania na informację stawiane przez modele analityczne.

Trzeba wziąć pod uwagę, że używane obecnie systemy analityczne pozwalają liczyć ryzyko operacyjne ze stosunkowo małą dokładnością dlatego też podejmowane są wysiłki na wdrażanie metod, które pozwoliłyby dokładniej wyznaczyć ryzyko. Napędza to rozwój nowych metodologii i narzędzi analitycznych, które muszą być zasilane odpowiednimi danymi. Proponowany Data Mart, który

powstał na podstawie analiz zapotrzebowania na informację dla wielu różnych modeli analitycznych, stanowi rozwiązanie tego problemu.

W literaturze omawiane są różne podejścia do kwantyfikacji wiedzy eksperckiej dotyczącej skutków zdarzeń operacyjnych. Proces ten polega zazwyczaj na wyrażeniu wiedzy i opinii eksperta w postaci odpowiedniego rozkładu prawdopodobieństwa.

Drugie zadanie polegało na zaproponowaniu nowego algorytmu kalibracji modeli analitycznych kwantyfikujących wiedzę ekspercką opartych na procesach Poissona. Brak możliwości bezpośredniego porównania opinii ekspertów z „twardym” danymi historycznymi wynika z faktu, że dostępny horyzont czasowy dla obserwacji jest z punktu widzenia ryzyka operacyjnego bardzo krótki i trzeba stosować różnego rodzaju uproszczenia i przybliżenia. Ocena metody oparta została na analizie właściwości algorytmu przy ewentualnej zmianie ocen eksperckich.

Scenariusze dotyczą dotkliwości i częstości wystąpienia strat. W obecnej praktyce wykorzystuje się metody oparte na bezpośrednim szacowaniu rozkładu w podejściu: a) „przedziałowym”, gdzie oceniane są grupy zdarzeń podzielonych na ustalone przedziały wartości strat, b) „percentylowym”, w którym ocenia się procentowy udział różnych typów zdarzeń w stosunku do ustalonej „puli” oraz c) ocenie indywidualnych zdarzeń. Ostatnie podejście zarezerwowane jest dla bardzo dużych (i rzadkich) wydarzeń.

W przypadku budowy scenariuszy dla ryzyka operacyjnego strategia kwantyfikacji jest szczególnie istotna ponieważ dotyczy zdarzeń rzadkich. Wszystkie używane modele sprowadzają się do klasy modeli parametrycznych tzn. na podstawie danych wybiera się odpowiednią parametryczną rodzinę rozkładów, a następnie estymuje nieznane parametry. Problemem jest więc zarówno wybór rodziny jak i proces estymacji. Warto zauważyć, że szacowaniu podlegają parametry rozkładów brzegowych, a nie rozkładów warunkowych co prowadzi do dodatkowych błędów. W pomiarze ryzyka operacyjnego, wybrane rozkłady wykorzystywane są do liczenia bardzo wysokich percentyli - rzędu 99.9%. Jeżeli dodać do tego obciążenia związane np. z aspektem psychologicznym występującym podczas zbierania danych jak np. obecność uznanego autorytetu lub przełożonego podczas warsztatów, widać że organizacja procesu pozyskania danych powinna być bardzo dokładnie zaplanowana

Od kilku lat dostępna jest teoretyczna metoda wykorzystująca procesy Poissona – metoda Duration. W modelu Duration scenariusz wygląda następująco: „Strata o wartości X lub wyższej zdarza się co D lat”. W praktyce metoda nie została wykorzystana z powodu braku odpowiednich procedur kalibracyjnych. (Frachot 2002) zaproponował metodę najmniejszych kwadratów zastosowaną do danych zbieranych w bezpośrednich szacowaniach okresu pomiędzy zdarzeniami przy jednoczesnym założeniu prostych rozkładów dla wysokości strat. Stosowanie skomplikowanych rozkładów wiąże się z koniecznością wprowadzenia prostego algorytmu przekładania intuicyjnych miar ryzyka rozumianych przez ekspertów na parametry modelu. W pracy wykorzystany został hybrydowy rozkład strat. Zastosowanie takiego rozwiązania pozwala dokładniej modelować zdarzenia rzadkie odgrywające w ryzyku operacyjnym bardzo ważną rolę. Zaletą proponowanej modyfikacji modelu jest oparcie się na bardzo intuicyjnych danych ocenianych przez ekspertów. Zbadana została elastyczność modelu przy wprowadzaniu istotnych zaburzeń do opinii ekspertów.

Dla porównania, przebadany został model łączenia opinii eksperckich z użyciem podejścia tzw. Supra-Bayes’a. Metodologia ta polega na obliczaniu poprawek do wstępnych szacunków na podstawie

dodatkowych opinii o „wartości” ekspertów. Niestety w ramach tej teorii występują niejednoznaczności w ocenie, które prowadzą do bardzo dużej niestabilności wyników.

W pracy zwrócono uwagę na możliwość stosowania teorii zbiorów rozmytych do oceny ryzyka operacyjnego. Takie podejście wydaje się obiecujące, niestety jest to podejście procesowe, tzn. wymaga ono dokładnego zdefiniowania procesów operacyjnych banku. Ze względu na brak takiego opisu banku w stosunku do zagrożeń generujących ryzyko operacyjne metody oparte na zbiorach rozmytych nie są stosowane.

Spis tabel i rysunków

SPIS TABEL:

Tabela 1. Przykładowa metryka KRI. Źródło opracowanie własne	57
Tabela 2. Metryka systemu. Źródło opracowanie własne	75
Tabela 3. Szereg czasowy wartości KRI, przypisanych do poszczególnych komórek projektu. Źródło opracowanie własne	75
Tabela 4. Wyznaczone statystyki szeregów KRI – w tym wartości progowe oraz krytyczne. Źródło opracowanie własne	75
Tabela 5. Informacje o stratach w ramach danego projektu, z podziałem na komórki. Źródło opracowanie własne	76
Tabela 6. Wyznaczone wartości kowariancji dla poszczególnych wierszy danego projektu. Źródło opracowanie własne	76
Tabela 7. Wyznaczone wartości kowariancji dla poszczególnych kolumn danego projektu. Źródło opracowanie własne	76
Tabela 8. Wyznaczone parametry dopasowanych rozkładów, wraz z ich przedziałami ufności – dla każdej komórki niezależnie. Źródło opracowanie własne	77
Tabela 9. Wybrane rozkłady dotkliwości – do dopasowania w danej komórce. Źródło opracowanie własne	77
Tabela 10. Wybrane rozkłady częstości – do dopasowania w danej komórce. Źródło opracowanie własne	77
Tabela 11. Wartości miar jakości dopasowania poszczególnych rozkładów dotkliwości do rzeczywistych rozkładów strat w danej komórce. Źródło opracowanie własne	77
Tabela 12. Wartości miar jakości dopasowania poszczególnych rozkładów częstości do rzeczywistych rozkładów strat w danej komórce. Źródło opracowanie własne	78
Tabela 13. Wybrane miary jakości dopasowania – osobno dla rozkładu dotkliwości i częstości (dla całego projektu). Źródło opracowanie własne	78
Tabela 14. Kategorie zdarzeń wymienione w dyrektywach nadzorczych (kategorie bazylejskie). Źródło „Dziennik Urzędowy Unii Europejskiej C 227”, 2005	86
Tabela 15. Linie biznesowe wymienione w dyrektywach nadzorczych (linie bazylejskie). Źródło: „Dziennik Urzędowy Unii Europejskiej C 227”, 2005	87
Tabela 16. Liczebność zdarzeń w podziale na typy zdarzeń bazylejskich i linie biznesowe bazylejskie. Źródło (BCBS 2003)	88
Tabela 17. Podział biznesu na 23 „komórki”. Źródło: Journal of Operational Risk 2006, "LDA at work: Deutsche Bank's approach to quantifying operational risk", F.Aue, M. Kalkbrener	89
Tabela 18. Porównanie ocen eksperckich z danymi historycznymi. Źródło (BCBS 2009a)	91
Tabela 19. Analiza obciążeń procesu elicytacji. Źródło (BCBS 2009b)	93
Tabela 20. Kwestionariusz do zbierania opinii ekspertów metodą percentylową. Źródło: "2008 Loss Data Collection Exercise", Accord Implementation Group Operational Risk, BCBS 2009	101
Tabela 21. Kwestionariusz do zbierania opinii ekspertów metodą przedziałową. Źródło: "2008 Loss Data Collection Exercise", Accord Implementation Group Operational Risk, BCBS 2009	102
Tabela 22. Kwestionariusz do zbierania opinii ekspertów metodą ryzyk indywidualnych. Źródło: "2008 Loss Data Collection Exercise", Accord Implementation Group Operational Risk, BCBS 2009	102
Tabela 23. Analiza scenariuszy w podziale na granularność. Źródło (BCBS 2009b)	104
Tabela 24. Liczba scenariuszy używanych w bankach. Źródło (BCBS 2009a)	105
Tabela 25. Przykładowa agenda panelu. Źródło opracowanie własne	110
Tabela 26. Przykładowe reguły definiujące Ryzyko Przetworzonego Czasu. Źródło (Hadjimichael 2009).	142
Tabela 27. Przykładowy kwestionariusz do zbierania danych jakościowych. Źródło opracowanie własne	147
Tabela 28. Przykładowy kwestionariusz do zbierania danych ilościowych. Źródło opracowanie własne	148
Tabela 29. Dane uzyskane w wyniku procesu samooceny. Źródło opracowanie własne	149
Tabela 30. Fragment tabeli z danymi samooceny. Źródło opracowanie własne	152
Tabela 31. Tabel z wynikami parametrów. Źródło opracowanie własne.	152
Tabela 32. Fragment tabeli z danymi samooceny. Źródło opracowanie własne	153
Tabela 33. Tabel z wynikami parametrów. Źródło opracowanie własne.	153
Tabela 34. Wartości VaR dla różnych poziomów ufności uzyskane na podstawie danych z przykładu. Źródło opracowanie własne.	155
Tabela 35. „Zaburzone” dane samooceny użyte do badania stabilności modelu. Źródło opracowanie własne.	155
Tabela 36. Wartości VaR dla różnych poziomów ufności uzyskane na podstawie różnych wersji „zaburzenia” dla modelu Log-normal/GPD. Źródło opracowanie własne	156
Tabela 37. Wartości VaR dla różnych poziomów ufności uzyskane na podstawie różnych wersji „zaburzenia” dla modelu log-normal. Źródło opracowanie własne	156
Tabela 38. „Sztuczny” scenariusz wyniku procesu samooceny. Źródło opracowanie własne	157
Tabela 39. „Sztuczny” scenariusz wyniku procesu samooceny. Źródło opracowanie własne	158
Tabela 40. Wyniki oszacowań wektora p^* w przykładzie metody Supra-Bayes. Źródło opracowanie własne	158
Tabela 41. „Sztuczny” scenariusz wyniku procesu samooceny. Źródło opracowanie własne	159
Tabela 42. Wyniki oszacowań wektora p^* w przykładzie metody Supra-Bayes. Źródło opracowanie własne	160

SPIS RYSUNKÓW:

Rysunek 1. Diagram "Gartner Magic Quadrant for Operational Risk Management". Źródło: Gartner, Inc., 2010	6
Rysunek 2. Schemat pokrycia zakresu danych przez różne źródła. Źródło opracowanie własne	9
Rysunek 3. Schemat Systemu Wspomagającego Zarządzanie Ryzykiem Operacyjnym. Źródło: materiały firmy Optial.	23
Rysunek 4. Przykładowy ekran służący do zbierania informacji o stratach. Źródło: materiały firmy SAS.	27
Rysunek 5. Przykład walidacji dla standardowego zdarzenia operacyjnego/straty. Źródło: materiały firmy Optial.	28
Rysunek 6. Przykładowy ekran przedstawiający akcję związaną z monitorowaniem działań kontrolnych. Źródło: materiały firmy Oracle.	29
Rysunek 7. Przykład mapy ryzyka typu „heat-map”. Źródło: materiały firmy Chase Cooper	31
Rysunek 8. Diagram połączeń różnych wymiarów ryzyka – podejście typu IMPLICIT Linking. Źródło materiały firmy Optial.	32
Rysunek 9. Diagram połączeń różnych wymiarów ryzyka – podejście typu EXPLICIT Linking. Źródło materiały firmy Optial	32
Rysunek 10. Przykładowy "ekran" scenariusza z odwołaniami do różnych planów działań oraz załącznika w postaci arkusza Excela zawierającego analityczne wyniki . Źródło: materiały firmy Optial	33
Rysunek 11. Przykładowy ekran dla KRI: pokazuje listę wskaźników dostępnych w systemie. Źródło: materiały firmy SAS	38
Rysunek 12. Przykładowy "ekran" audytu i kontroli poprawności działań. Źródło: materiały firmy List Group	39
Rysunek 13. Przykład raportów graficznych uzyskanych przy użyciu aplikacji BI. Źródło materiały firmy Optial	42
Rysunek 14. Schemat logiczny przetwarzania danych w procesie obliczania ryzyka operacyjnego. Źródło: opracowanie własne na podstawie "The LDA approach for Operational Risk", RMG, 2003.	44
Rysunek 15. Podstawowy schemat bazy danych systemu Ryzyka Operacyjnego, Źródło: opracowanie własne	45
Rysunek 16. Baza Zdarzeń i Strat - Modułu Danych Wewnętrznych. Źródło: opracowanie własne	46
Rysunek 17. Baza danych scenariuszy parametrycznych systemu Ryzyka Operacyjnego. Źródło: opracowanie własne	46
Rysunek 18. Baza danych scenariuszy nieparametrycznych systemu Ryzyka Operacyjnego. Źródło: opracowanie własne	47
Rysunek 19. Baza danych wskaźników KRI systemu Ryzyka Operacyjnego. Źródło: opracowanie własne	47
Rysunek 20. Baza danych wymiarów układu systemu Ryzyka Operacyjnego. Źródło: opracowanie własne	48
Rysunek 21. Podsystem słowników systemu Ryzyka Operacyjnego. Źródło: opracowanie własne	48
Rysunek 22. Baza danych podsystemu ubezpieczeń systemu Ryzyka Operacyjnego. Źródło: opracowanie własne	49
Rysunek 23. Baza danych podsystemu działań zaradczych systemu Ryzyka Operacyjnego. Źródło: opracowanie własne	49
Rysunek 24. Schemat wyliczania ryzyka VaR. Źródło: opracowanie własne	50
Rysunek 25. Schemat procesu przetwarzania modeli analitycznych. Źródło: opracowanie własne	50
Rysunek 26. Procesy realizowane w ramach modułu KRI. Źródło: opracowanie własne	52
Rysunek 27. Diagram -przypadki użycia- realizowane w ramach modułu KRI. Źródło: opracowanie własne	54
Rysunek 28. Diagram -przypadki użycia- realizowane w ramach modułu KRI. Źródło: opracowanie własne	55
Rysunek 29. Zbieranie danych o Zatwierdzonym KRI w postaci workflow. Źródło: opracowanie własne	57
Rysunek 30. Diagram -przypadki użycia- realizowane w ramach modułu KRI. Źródło: opracowanie własne	58
Rysunek 31. Przykładowa prognoza KRI. Źródło: opracowanie własne	58
Rysunek 32. Diagram -przypadki użycia- realizowane w ramach modułu KRI. Źródło: opracowanie własne	59
Rysunek 33. Przykładowe scenariusze KRI uzyskane metodą Monte Carlo. Źródło: opracowanie własne	59
Rysunek 34. Analiza regresji jest używana do potwierdzania użyteczności danego wskaźnika KRI. Źródło: opracowanie własne na podstawie A.Mastro, M. Haubenstock „Operational Risk”, The RMA Journal, 2004	60
Rysunek 35. Diagram -przypadki użycia- realizowane w ramach modułu KRI. Źródło: opracowanie własne	60
Rysunek 36. Procesy realizowane w ramach modułu RCSA. Źródło: opracowanie własne	61
Rysunek 37. Diagram -przypadki użycia- realizowane w ramach modułu RCSA. Źródło: opracowanie własne	62
Rysunek 38. Schemat wyliczania ryzyka VaR w ramach modułu RCSA. Źródło: opracowanie własne	63
Rysunek 39. Schemat integracji modeli ryzyka VaR. Źródło: opracowanie własne	63
Rysunek 40. Schemat integracji modeli ryzyka VaR. Źródło: opracowanie własne	64
Rysunek 41. Diagram -przypadki użycia- realizowane w ramach modułu VaR. Źródło: opracowanie własne	65
Rysunek 42. Schemat części I procesów VaR.. Źródło: opracowanie własne	67
Rysunek 43. Schemat części II procesów VaR.. Źródło: opracowanie własne	67
Rysunek 44. Schemat tabel używanych w procesach VaR. Źródło: opracowanie własne	68
Rysunek 45. Schemat tabel używanych w procesach skalowania VaR. Źródło: opracowanie własne	69
Rysunek 46. Schemat tabel używanych w procesach kalibracji modeli częstości VaR. Źródło: opracowanie własne	70
Rysunek 47. Schemat tabel używanych w procesach kalibracji modeli dotkliwości VaR. Źródło: opracowanie własne	71
Rysunek 48. Schemat tabel używanych w procesach wyliczania miar zależności VaR. Źródło: opracowanie własne	72
Rysunek 49. Schemat tabel używanych w procesach testowania rozkładów częstości VaR.. Źródło: opracowanie własne	72
Rysunek 50. Schemat tabel używanych w procesach testowania rozkładów dotkliwości VaR. Źródło: opracowanie własne	73
Rysunek 51. Schemat tabel używanych w procesach silnika Monte Carlo VaR. Źródło: opracowanie własne	74
Rysunek 52. Diagram przepływu informacji pomiędzy poszczególnymi procesami zarządzania ryzykiem operacyjnym. Źródło: opracowanie własne	81
Rysunek 53. Schemat przetwarzania danych o stratach z wykorzystaniem bazy Global SAS. Źródło opracowanie własne.	83
Rysunek 54. Schemat procesprzeprowadzenia warsztatów. Źródło: (Gertman 2006)	106
Rysunek 55. Schemat kalibracji w przypadku ekspertów, którzy udzielają odpowiedzi na pytania (zmienne) bazowe. Liczba realizacji pokrywa się z odpowiednimi przedziałami {0.10, 0.45, 0.30, 0.15}. Źródło własne opracowane na podstawie (Westra 2011)..	125

Rysunek 56. Schemat kalibracji regresyjnej dla trzech ekspertów oceniających percentyle= (0.05, 0.10, 0.50, 0.90, 0.95). Źródło opracowanie własne.	125
Rysunek 57. Najwyższy szczebel struktury Ryzyka Podejścia do Lądowania i Ryzyka Wypadku przy Lądowaniu. Źródło: (Hadjimichael 2009).	141
Rysunek 58. Fragment struktury ryzyka Niskiego Poziomu. Źródło (Hadjimichael 2009).	141
Rysunek 59. Przykładowa struktura z węzłem pośrednim. Źródło (Hadjimichael 2009).	143
Rysunek 60. Funkcje przynależności dla czynnika DYŻURY . Źródło (Hadjimichael 2009).	143
Rysunek 61. Funkcje przynależności dla liczb rozmytych {2, 4, 6, 8, 10, 12}. Źródło (Hadjimichael 2009).	144
Rysunek 62. Przykładowe drzewo decyzyjne. Źródło (Hadjimichael 2009).	145
Rysunek 63. Proces zbierania danych w procesie samooceny. Źródło opracowanie własne.	146
Rysunek 64. Wykres gęstości dla „typowej” straty omawianego przykładu. Źródło opracowanie własne.	152
Rysunek 65. Wykres dystrybucyjności rozkładu Log-normal / GPD uzyskanego na danych z przykładu. Źródło opracowanie własne.	154
Rysunek 66. Wykres wysokich percentyli dystrybucyjności rozkładu Log-normal / GPD uzyskanego na danych z przykładu. Źródło opracowanie własne.	154
Rysunek 68. Wartości dystrybucyjności zagregowanej straty dla okresu 1 roku dla różnych wersji „zaburzenia”. Źródło opracowanie własne.	155
Rysunek 69. Wyniki wartości $p1^*$ dla różnych wag w_j w przykładzie metody Supra-Bayes. Źródło opracowanie własne.	159

11. Literatura

- 1 Agostini A., Talamo P., Vecchione V., „Combining operational loss data with expert opinions through advanced credibility theory”, *The Journal of Operational Risk* (3–28), 2010
- 2 Aparicio J., Keskiner E., (2004),” A Review of Operational Risk Quantitative Methodologies Within the BASEL-II Framework”, Accenture Technology Labs, France
- 3 Aspinall W.,„Expert Judgment Elicitation using the Classical Model and EXCALIBUR”, International Expert Advisory Group on Risk Modeling,2008
- 4 Aue F., Kalkbrener M. (2007)“LDA at work:Deutsche Bank's approach to quantifying operational risk”, *Journal of Operational Risk*(49-93).
- 5 Baud N., Frachot A., Roncalli T. (2002), “Internal data, external data and consortium data for operational risk measurement: How to pool data properly? “.
- 6 Bazzarello D., Crielard B., Piacenza F., Soprano A., (2006), “Modeling insurance mitigation on operational risk capital”, *Journal of Operational Risk*.
- 7 BCBS , “Working Paper on the Regulatory Treatment of Operational Risk”, Basel Committee on Banking Supervision, 2001
- 8 BCBS, “The 2002 Loss Data Collection Exercise for Operational Risk: Summary of the Data Collected”, Basel Committee on Banking Supervision, 2003
- 9 BCBS ,”Results from the 2008 Loss Data Collection Exercise for Operational Risk”, Basel Committee on Banking Supervision, 2009a
- 10 BCBS ,”Observed range of practice in key elements of Advanced Measurement Approaches (AMA)”, Basel Committee on Banking Supervision, 2009b
- 11 Bee M. (2006). Estimating and simulating loss distributions with incomplete data, *Oprisk and Compliance*, 7 (7), 38-41.
- 12 Berger J.O. “Statistical Decision Theory and Bayesian Analysis”, Springer Series in Statistics, 1985
- 13 Boring, R.L.,”Cognition and Psychological Scaling: Model, Method, and Application of Constrained Scaling”, PhD Dissertation, Carleton University, Ottawa, Canada,2004
- 14 Boring R., at al. „Simplified Expert Elicitation Guideline For Risk Assessment Of Operating Events”, Proceedings of the Eighth International Conference on Probabilistic Safety Assessment & Management (PSAM), 2005
- 15 Boring R., L., “How Many Performance Shaping Factors are Necessary for Human Reliability Analysis?”, INL/CON-10-18620 Preprint 2010
- 16 Brandts, Silke N.(2004), "Operational Risk and Insurance: Quantitative and Qualitative Aspects", Basel Meetings Paper. Available at SSRN: <http://ssrn.com/abstract=493082>
- 17 Brown D.J., Wang J.T. (2005): Implementing an AMA for Operational Risk Implementing an AMA for Operational Risk, presentation Federal Reserve Bank of Boston, May 19, 2005
- 18 Brunner M., at all, „Fat tails, expected shortfall and the Monte Carlo method”, *The Journal of*

Operational Risk (81–88), 2009

- 19 Buch-Kromann T., „Comparison of tail performance of the Champernowne transformed kernel density estimator, the generalized Pareto distribution and the g-and-h distribution”, *The Journal of Operational Risk* (43–67), 2009
- 20 Carvalho R., S., Migon H., S., Paez M., S., “Dynamic Bayesian models as an alternative to the estimation of operational risk measures”, *Journal of Operational Risk* (25–49), 2008
- 21 Cheg F. et al. (2007), “Modeling operational risk in processes”, *Journal of Operational Risk* (73–98)
- 22 Chernobai et al. (2007a): *Operational risk: A Guide to Basel II Capital Requirements, Models, and Analysis*, Wiley Finance, New Jersey
- 23 Chernobai A., S., Rachev S., T., Fabozzi F., J., “Operational Risk A Guide to Basel II Capital Requirements, Models, and Analysis” John Wiley & Sons, Inc 2007b
- 24 Ciesielski Z., Zieliński R., „Wyglądanie Dystrybucyj Empirycznych”, XXXVII Konferencja Zastosowań Matematyki, 2008
- 25 Clemen R., T., “Combining forecasts: A review and annotated”, *International Journal of Forecasting* 5 (1989) 559-583
- 26 Clemen T. R., Winkler R., L., “Aggregation of Expert Probability Judgments”, *Risk Analysis*, 19, 187-203., 1999
- 27 Clemen T. R., Winkler R., L., “Combining Probability Distributions From Experts in Risk Analysis”, *Risk Analysis*, Vol. 19, No. 2, 1999
- 28 Cooke R., M., “Experts in uncertainty: opinion and subjective probability in science/”, Oxford University Press, 1991
- 29 Cruz M. (2002). *Modelling, Measuring and Hedging Operational Risk*. John Wiley & Sons.
- 30 Dahan H., Dionne G., (2007), „Scaling Models for the Severity and Frequency of External Operational Loss Data”, CRCiRM Working Paper 07-01, Canada
- 31 Davies J., Finlay M., McLenaghan T., Wilson D., (2006), “Key Risk Indicators – Their Role in Operational Risk Management and Measurement”, RiskBusiness International Limited.
- 32 De Fontnouvelle P., DeJesus-Rueff V., Jordan J. Rosengren E. (2003): *Using Loss Data to Quantify Operational Risk*, Technical report, Federal Reserve Bank of Boston
- 33 Deloitte (2007): *Global Risk Management Survey*, 5th edition
- 34 Dutta K. and J. Perry (2006). *A tale of tails: An empirical analysis of loss distribution models for estimating operational risk capital*. Federal Reserve Bank of Boston, Working Papers No. 06-13.
- 35 Dutta K., K., Babbel D., F., “Scenario Analysis in the Measurement of Operational Risk Capital: A Change of Measure Approach”, Working Paper #12-15. *Journal of Risk and Insurance*, 2010
- 36 Ebnöther S., Vanini P., McNeil A., Antolinez P., “Operational Risk: A Practitioner's View”, National Centre of Competence in Research Working Paper No. 52, 2003
- 37 Ergashev B., “Estimating the lognormal-gamma model of operational risk using the Markov chain Monte Carlo method”, *The Journal of Operational Risk* (35–57), 2009

- 38 Feng Ch., Nitin J., Wanli M., Ramachandran B., Gamarnik D., (2007), "Modeling operational risk in
- 39 Fheili M.I. (2006)," Developing human resources key risk indicators – Know Your Staff (KYS) practices",
Journal of Operational Risk (71–85)
- 40 Folpmers M., "A practical guide to measuring operational risk using subjective data through copulas and
scenario analysis", The Journal of Operational Risk (63–74) Volume 3/Number 3, Fall 2008
- 41 Frachot A., Georges P., Roncalli T. (2001): Loss Distribution Approach for operational risk Groupe de
Recherche Operationnelle, Credit Lyonnais, France
- 42 Frachot A., Moudoulaud O., Roncalli T. (2003): Loss Distribution Approach in Practice, Groupe de
Recherche Operationnelle, Credit Lyonnais, France
- 43 Fumika O., "A Literature Review on the Use of Expert Opinion in Probabilistic Risk Analysis", Policy,
Research working paper, no. WPS 3201, 2004
- 44 Gabaix X. (2008) „Power Laws in Economics and Finance”, NBER Working Paper 14299, Cambridge.
- 45 Garthwaite P.H., Kadane J.B., O’Hagan A., (2005), „Statistical Methods for Eliciting Probability
Distributions”, JASA (v100, n470)
- 46 Christian Genest, Mark Schervish, "Modeling Expert Judgments for Bayesian Updating", The Annals of
Statistics, 1985 Vol 13/3, 1198-1212
- 47 Gertman, D., Blackman, H., Marble, J., Byers, J., Haney, L., & Smith, C. , "The SPAR-H Human Reliability
Analysis Method, NUREG/CR", DC: US Nuclear Regulatory Commission, 2006
- 48 Giacometti R., Rachev S., Chernobai A., (2007), "Heavy-tailed distributional model for operational
losses", Journal of Operational Risk (55–90).
- 49 Giudici P., "Scorecard Models for Operational Risk Management", Atti Convegno Intermedio SIS, 2007
- 50 Gregoriou G., N., "Operational Risk toward Basel III Best Practices and Issues in Modeling, Management,
and Regulation, John Wiley & Sons, 2009
- 51 Hadjimichael M., "A fuzzy expert system for aviation risk assessment", Expert Systems with Applications
36 (2009)
- 52 Heru N.S. (2004) , "Operational Risk Analysing and Scaling Operational Risk Loss Data", Erasmus
University Rotterdam, Netherlands.
- 53 Heru S. N., van den Berg J., Lourenco C. M. , Marc L., (2006) "An econometric model to scale operational
losses", Journal of Operational Risk (11–31)
- 54 Hickey A.M., Davis A., M., "Requirements Elicitation and Elicitation Technique: A Model for Two
Knowledge-Intensive Software Development Processes", IEEE Computer Society, 2003
- 55 Hukki K, „A Formal Process for Elicitation and Validation of Expert Judgments for Safety Case in the
Context of Spent Nuclear Fuel Management" POSIVA, Working Report 2008
- 56 Immaneni A., Mastro C., Haubensstock M., "A Structured Approach to Building Predictive Key Risk",
Indicators The RMA Journal, v86n9, 42–47, 2004.
- 57 Jobst A., A., „Operational risk: the sting is still in the tail but the poison depends on the dose", Journal of
Operational Risk (3–59), 2007

- 58 Jorion, P. (2000): Value at Risk: The New Benchmark for Managing Financial Risk, 2nd edition, McGraw-Hill, New York
- 59 Kilavuka M.,I., „Managing operational risk capital in financial institutions”, Journal of Operational Risk (67–83), 2008
- 60 Klugman S.A., Panjer H., Willmot G.E., (2008), “Loss Models: from Data to Decision”, John Wiley & Sons, Inc., 3rd ed.
- 61 Kuncheva, L., I., “Combining pattern classifiers: methods and algorithms”, by John Wiley & Sons, 2004
- 62 Lindqvist P., Nordänger U., K., “(Mis- ?) using the E-Delphi Method: An Attempt to Articulate the Practical Knowledge of Teaching”, Journal of Research Methods and Methodological Issues, 2007
- 63 Makarov M., “Extreme value theory and high quantile Convergence”, Journal of Operational Risk (51–57), 2006
- 64 Mignola G., Ugocioni R., (2006), „Effect of a data collection threshold in the loss distribution approach”, Journal of Operational Risk (35–47).
- 65 Moscadelli M. (2004) „The Modelling of Operational Risk: Experience with the Analysis of the Data Collected by the Base Committee”, Bank of Italy, Banking Supervision Department.
- 66 Noortwijk J.,M., Dekker R., Cooke R.,M., “Expert Judgment in Maintenance Optimization”, IEEE Transactions on Reliability, v41n3,1992
- 67 O’Hagan, A., & Oakley, J.E., “Probability is perfect, but we can’t elicit it perfectly”. Reliability Engineering and System Safety, 85, 239-248, 2004
- 68 Operational Risk Sound Practice Guidance, “Risk Control and Self Assessment”, Institute of Operational Risk, 2010
- 69 OPRisk Evolution List Group S.p.A. “User Guide”, 2008
- 70 Optial UK Limited, “Optial Operational Risk Management System - Technical Aspects”, 2009
- 71 Oracle Financial Services, „Overview of Reveleus Operational Risk Solution”, 2008
- 72 Panjer, H. (2006): Operational Risk: Modeling Analytics, Wiley.
- 73 Peters G.W., Sisson S.I. (2006), „Bayesian inference, Monte Carlo sampling and operational risk”, Journal of Operational Risk (27–50).
- 74 Peters W., G., Shevchenko P., V., Wauthrich M., V., “Dynamic operational risk: modeling dependence and combining different sources of information”, The Journal of Operational Risk 4(2), pp. 69-104, 2009
- 75 Power, M. (2005): The invention of operational risk, Review of International Political Economy, October 2005, pp. 577–599.
- 76 RCS, “RCS Company and Product Overview”, 2007
- 77 Roback P., J., Givens G., H., “Supra-Bayesian Pooling of Priors Linked by a Deterministic Simulation Model”, Communications in Statistics - Simulation and Computation, 30-3, 2001
- 78 Rosengren (2003): Operational Risk, presentation Federal Reserve Bank of Boston, May 1, 2003

- 79 Ruhm D.L., Atkins J. "Elicitation and Elucidation of Risk Preferences ", CAS Working Party on the Elicitation and Elucidation of Risk Preferences, 2005
- 80 Ryan S, „Chase Cooper Overview”,2008
- 81 Samad-Khan A. (2005): Assessing & Measuring Operational Risk Why COSO is Inappropriate, presentation in London, January 18, 2005
- 82 SAS, "SAS OpRisk VaR 3.4: User's Guide",2007
- 83 Shevchenko P.,V., Wüthrich M.,V, "The Structural Modelling of Operational Risk via Bayesian inference: Combining Loss Data with Expert Opinions", The Journal of Operational Risk 1(3), pp. 3-26, 2006
- 84 Shevchenko P.V.(2009), "Implementing Loss Distribution Approach for Operational Risk", CSIRO Mathematical and Information Sciences, Sydney.
- 85 Temnov G., Warnung R., „A comparison of loss aggregation methods for operational risk", Journal of Operational Risk (3–23),2008
- 86 Teplý, P. (2006): Regulatory Risk and Issues of Basel II in Central European Economies, Presentation at Massey University in Palmerston North, New Zealand, June 2006
- 87 Teplý, P., Černohorská L., Diviš K. (2007): Implications of the New Basel Capital Accord for European Banks , E+M Journal, Czech Republic, 2, pp. 58-64.
- 88 Tripp T.M at all, "Quantifying Operational Risk in General Insurance Companies", B.A.J. 10, V, 919-1026 (2004)
- 89 Van Leyveld I. et al. (2007): Economic Capital Modelling: Concepts, Measurement and Implementation, Laurie Donaldson, London.
- 90 Vasilescu L.,G. "New trends Regarding the Operational Risk in Financial Sector", Journal Revista Tinerilor Economisti, University of Craiova 2008
- 91 Wallsten T.,S.,DiederichA., „Understanding pooled subjective probability estimates", Mathematical Social Sciences 41 (2001) 1–18
- 92 Westra M.,„Modelling expert opinions on operational risk in pension Funds", Master thesis Rijksuniversiteit Groningen, 2011
- 93 Xua Z., Khoshgoftaar T.,M, Allen E.,B., "Application of fuzzy expert systems in assessing operational risk of software" Information and Software Technology 45 (2003) 373–388

Moje publikacje z lat 2007 -2012

1. Grzybowska U., Karwański M., „Wykorzystanie miar matematycznych i biznesowych do porównania modeli macierzy migracji stosowanych w analizie ryzyka kredytowego”, *Metody ilościowe w badaniach ekonomicznych*. T. 12, nr 2 / red. Bolesław Borkowski. - Warszawa, 2011. - S. 168-179
2. Karwański M., Szczesny W., “The quantification of expert opinion in operational risk”, *Computer algebra systems in teaching and research : mathematical modeling in physics, civil engineering, economics, and finance* / ed. Leszek Gadomski, Mirosław Jakubiak, Alexander N.
3. Karwański M., Jałowiecki P., Orłowski A.” The perspectives of Bayesian methods for modeling financial reserves in insurance”, *Acta Universitatis Lodziensis. Folia Oeconomica* 2009, nr 228, s. 369-376
4. Odrzygóźdź Z., Karwański M., Szczesny W, „ Business Intelligence - Application and trends in development “, *Information systems in management III* / ed. by Waldemar Karwowski, Arkadiusz Orłowski. - Warsaw : WULS Press, 2009. - S. 78-87
5. Szczesny W, Karwański M., „Some key elements of implementation Internal Operational Risk Model with the Business Intelligence System tools”, *Information systems in management III* / ed. by Waldemar Karwowski, Arkadiusz Orłowski. - Warsaw : WULS Press, 2009. - S.95-105
6. Karwański M., „Some Elements of System Supporting Operational Risk Management – Quantitative Approach In Self-Assesment”, “, *Information systems in management III* / ed. by Waldemar Karwowski, Arkadiusz Orłowski. - Warsaw : WULS Press, 2009. - S. 40-49
7. Jałowiecka E., Karwański M., Orłowski A., „Porównanie efektywności wybranych modeli zarządzania ryzykiem rynkowym”, *Metody ilościowe w badaniach ekonomicznych : analiza rynków finansowych. Modele ekonometryczne 9* / red. nauk. Zbigniew Binderman. - Warszawa : Wydawnictwo SGGW, 2008. - S. 33-42
8. Jałowiecki P., Karwański M, „System modelowania i symulacji biznesowych jako propozycja platformy edukacyjnej”, *Wybrane problemy elektronicznej gospodarki : monografia* / pod red. Mariana Niedźwiedzińskiego, Katarzyny Lange-Sadzińskiej. - Łódź, 2008. - S. 119-130
9. Karwański M., Szczesny W. „Statistical generator of financial scenarios supporting the process of calculating the reserves in the insurance company”, *Information systems in management II* / ed. by Andrzej Jakubiec, Waldemar Karwowski, Arkadiusz Orłowski. - Warsaw : WULS Press, 2008. - S. 30-40
10. Karwański M., Szczesny W, „Analiza ryzyka modelu szacowania rezerw IBNR w zakładzie ubezpieczeniowym. Modele stochastyczne dla danych zagregowanych i indywidualnych”, *Prace Naukowe Uniwersytetu Ekonomicznego we Wrocławiu* 2008, Nr 1207, s. 116-127
11. Karwański M., Szczesny W, „Optymalizacja modeli "long-run" w prognozowaniu procesów finansowych”, *Metody ilościowe w badaniach ekonomicznych : analiza rynków finansowych. Modele ekonometryczne 9* / red. nauk. Zbigniew Binderman. - Warszawa : Wydawnictwo SGGW, 2008. - S. 159-168
12. Karwański M., Jałowiecki P., Orłowski A.,” System pomiaru ryzyka rynkowego w długim horyzoncie czasowym EAR”, *Zeszyty Naukowe SGGW w Warszawie. Ekonomika i Organizacja Gospodarki Żywnościowej* 2008, nr 66, s. 5-16

13. Odrzygóźdź Z., Karwański M., Szczesny W, „IT tools supporting management in large financial institution “, Information systems in management II / ed. by Andrzej Jakubiec, Waldemar Karwowski, Arkadiusz Orłowski. - Warsaw : WULS Press, 2008. - S. 113-123
14. Szczesny W, Karwański M., “The role of the WAP tools in choice of advanced analytical CRM system at large retail bank”, Information systems in management II / ed. by Andrzej Jakubiec, Waldemar Karwowski, Arkadiusz Orłowski. - Warsaw : WULS Press, 2008. - S. 177-187
15. Jałowiecka E., Jałowiecki P., Karwański M. , „Prognozy produkcji papierosów w Polsce w latach 2006-2010 przy użyciu modeli adaptacyjnych i autoregresyjnych”, Metody ilościowe w badaniach ekonomicznych. 8 / red. nauk. Bolesław Borkowski. - Warszawa : Wydawnictwo SGGW, 2007. - S. 153-162
16. Karwański M., Jałowiecki P., „Koncepcja prowadzenia przedmiotu ‘Statystyczna analiza i przetwarzanie danych w Systemie SAS’ w formie Case-Study”, Systemy informatyczne w zarządzaniu / red. nauk. Waldemar Karwowski, Arkadiusz Orłowski. - Warszawa : Wydawnictwo SGGW, 2007. - S. 7-25