Chociaż symulacje biznesowe nie są nowym pomysłem, korzystanie ze sztucznej inteligencji (nawet w formach LLM) jest teraz bardziej możliwe do zarchiwizowania przez średnie i małe firmy ze względu na rosnącą dostępność i spadające koszty AI. Takie przecięcie modelowania biznesowego i sztucznej inteligencji stworzyło pilną potrzebę standaryzowanych, matematycznie ustrukturyzowanych reprezentacji komponentów biznesowych, które mogą być przetwarzane skuteczniej przez duże modele językowe (LLM) niż tradycyjne raporty narracyjne. Podczas gdy z jednej strony wydaje się, że korzystanie z takich środków nie jest konieczne ze względu na zdolność interpretacji AI, z drugiej strony można uzyskać niewątpliwie lepsze wyniki swoich monitów, jeśli AI nie jest zmuszona interpretować tych danych, ale otrzymuje je w ustrukturyzowanym formacie.

W rzeczywistości, dzięki komputeryzacji, cyfrowe modelowanie biznesowe jest już obecne w naszym środowisku od jakiegoś czasu. Istnieje więc kilka sposobów, w jaki możesz stworzyć cyfrową reprezentację biznesową, która może być przydatna dla Ciebie, zarządu i AI.

Uwaga: generalnie unikam dołączania obrazów generowanych przez AI, ale w przypadku tego artykułu było to tak kuszące, że postanowiłem zrobić wyjątek.

Czym jest „cyfrowy bliźniak” w kontekście biznesowym?

Cyfrowi bliźniacy w modelowaniu biznesowym to **wirtualne reprezentacje rzeczywistych podmiotów biznesowych**, procesów lub systemów, które są stale aktualizowane o dane na żywo. Modele te odzwierciedlają strukturę, zachowanie i wydajność ich fizycznych odpowiedników, umożliwiając organizacjom symulowanie, analizowanie i przewidywanie wyników w dynamicznym środowisku. Integrując dane z różnych źródeł — takich jak czujniki IoT, aplikacje korporacyjne, dane finansowe i zapisy historyczne — cyfrowe bliźniaki oferują holistyczny obraz operacji biznesowych, pomagając interesariuszom i członkom zarządu podejmować świadome decyzje, identyfikować nieefektywności i testować scenariusze bez zakłócania rzeczywistych przepływów pracy.

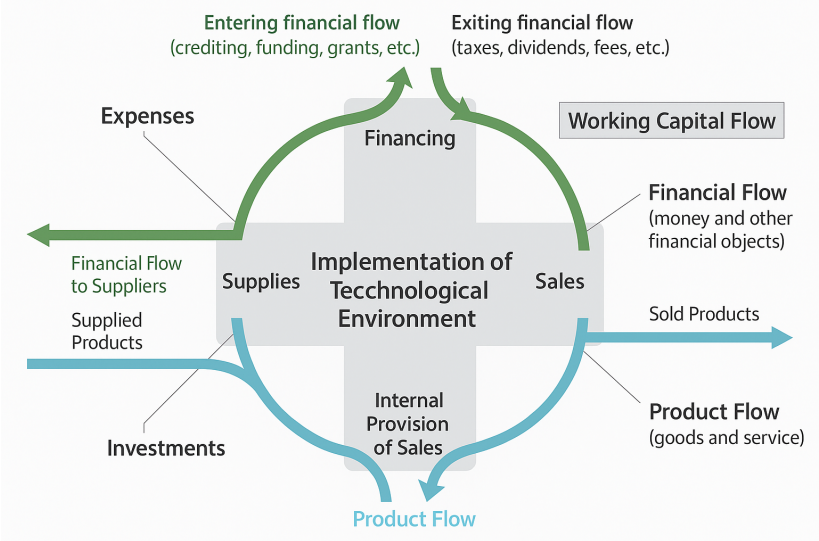
W kontekście modelowania biznesowego cyfrowe bliźniaki wykraczają poza statyczne diagramy lub arkusze kalkulacyjne, oferując interaktywne modele w czasie rzeczywistym, które ewoluują wraz z biznesem. Umożliwiają organizacjom wizualizację zależności, monitorowanie kluczowych wskaźników wydajności i

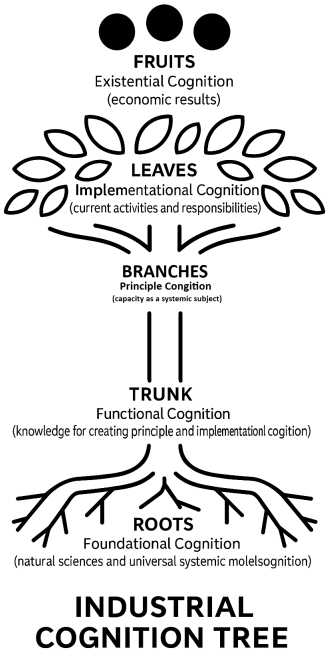
prognozowanie wpływu strategicznych zmian, takich jak wprowadzenie nowej linii produktów, identyfikacja marnotrawstwa lub restrukturyzacja łańcucha dostaw. W połączeniu ze sztuczną inteligencją i uczeniem maszynowym cyfrowe bliźniaki stają się potężnymi narzędziami do ciągłego doskonalenia, ograniczania ryzyka i innowacji, co czyni je niezbędnymi do zwinnego podejmowania decyzji opartych na danych w nowoczesnych przedsiębiorstwach.

Ontologiczne i semantyczne modele biznesowe

Ontologia modelu biznesowego (BMO)

Ontologia modelu biznesowego stanowi znaczący postęp w tworzeniu matematycznie ustrukturyzowanych reprezentacji przedsiębiorstw. Te kompleksowe ramy dostarczają formalnej wiedzy na temat organizacji strukturalnej, funkcjonowania i niezbędnych pojęć dotyczących przedsiębiorstw za pośrednictwem dwóch głównych platform poznawczych. **Industrial Cross** wyjaśnia przedsiębiorstwo jako obiekt systemowy składający się z pięciu systemów technologicznych, które obejmują liczne specyficzne obiekty i procesy, definiując wszystkie elementy, ich relacje i właściwości w sposób umożliwiający modelowanie matematyczne w wymiarach strategicznych, taktycznych i operacyjnych. **Industrial Cognition Tree** zapewnia kompleksowe zrozumienie zarządzania wiedzą poprzez hierarchicznie ustrukturyzowane poznawcze specyficzne dla przedsiębiorstwa, wyjaśniając przedsiębiorstwo jako podmiot systemowy posiadający poznawcze i umożliwiając zarządzanie poznawczą bazą przedsiębiorstwa.



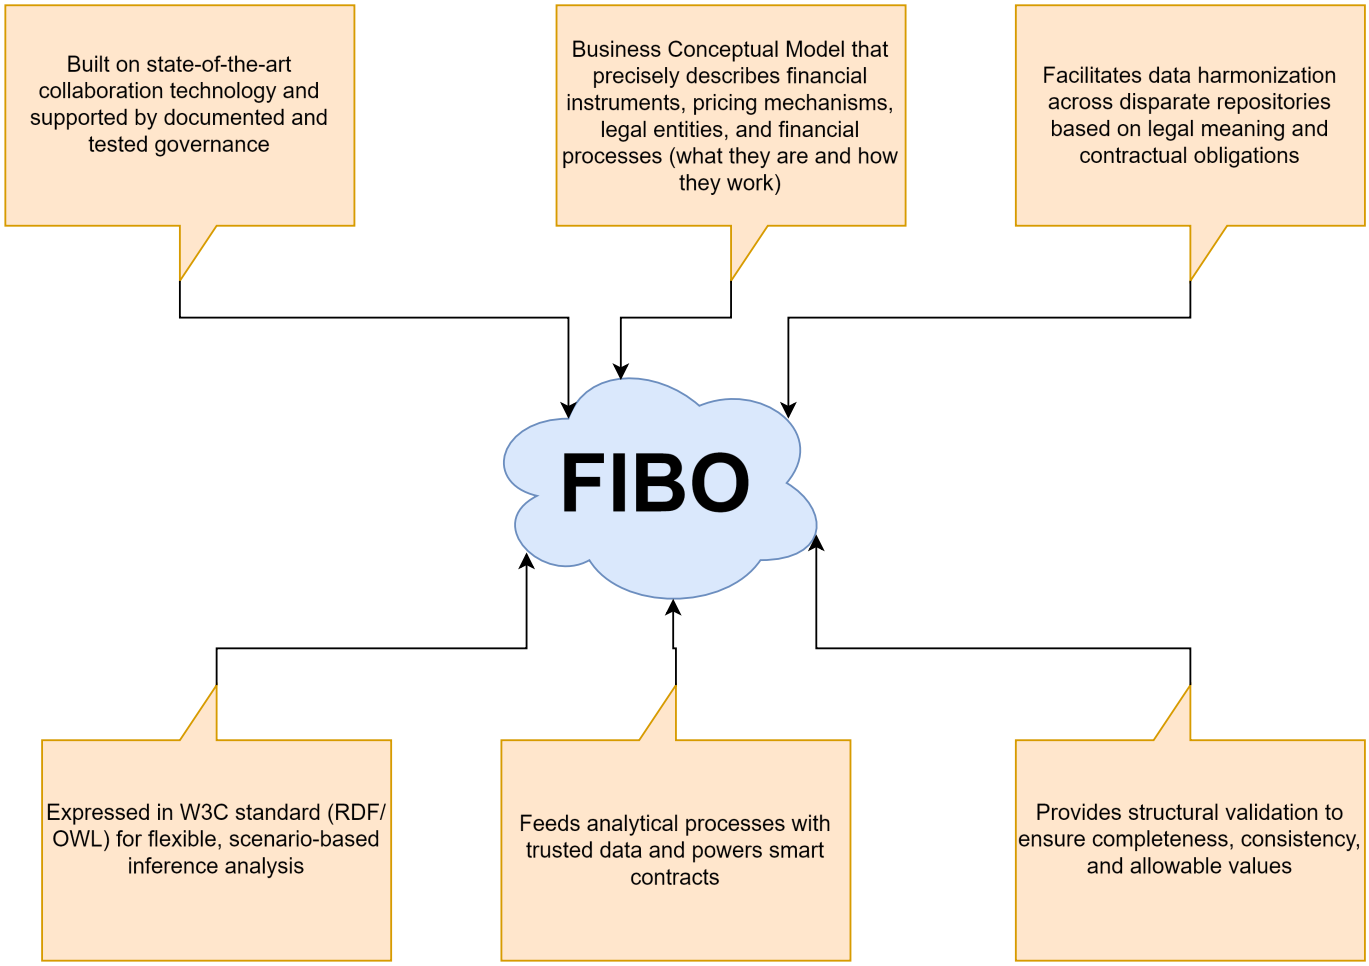


To podejście ontologiczne tworzy podstawową strukturę matematyczną, która może reprezentować podmioty biznesowe jako obiekty formalne o zdefiniowanych właściwościach, relacjach i ograniczeniach. Systematyczna natura BMO sprawia, że nadaje się do przetwarzania LLM, ponieważ zapewnia jasne definicje semantyczne i relacje logiczne, które można wyrazić w formalnych językach logicznych.

Ontologia biznesu branży finansowej (FIBO)

Ontologia biznesu branży finansowej (FIBO) ilustruje **jak złożone koncepcje finansowe można precyzyjnie ustrukturyzować do interpretacji maszynowej**. Definiuje kluczowe elementy istotne dla aplikacji biznesowych w finansach i mapuje ich wzajemne powiązania, umożliwiając danym niesienie jasnego, kontekstowego znaczenia. Zbudowany przy użyciu Web Ontology Language (OWL) i znormalizowany przez World Wide Web Consortium (W3C), FIBO wykorzystuje logikę opisową, aby zapewnić, że każda koncepcja jest jasno zdefiniowana i możliwa do zinterpretowania zarówno przez ludzi, jak i maszyny.

Financial Industry Business Ontology (FIBO)



Logiczna struktura FIBO sprawia, że nadaje się ono do przetwarzania dużych modeli językowych (LLM), oferując formalne definicje semantyczne, które eliminują niejednoznaczności z terminów i relacji finansowych. Jej koncepcje, udoskonalane z czasem poprzez przegląd przez firmy członkowskie branży, odzwierciedlają wspólne zrozumienie w całym sektorze finansowym, zapewniając solidne podstawy do rygorystycznego modelowania matematycznego systemów biznesowych w finansach.

SAILINGBYTE

Formaty wymiany danych strukturalnych

Taksonomie XBRL dla sprawozdawczości finansowej

XBRL (eXtensible Business Reporting Language) stanowią **jeden z najbardziej dojrzałych przykładów matematycznej strukturyzacji danych finansowych przedsiębiorstw**. Taksonomie te pełnią funkcję słowników do raportowania, zapewniając cyfrowe definicje pojęć biznesowych i umożliwiając cyfrowe raportowanie za pomocą ustrukturyzowanych systemów tagowania. Raporty cyfrowe działają poprzez tagowanie każdego zgłoszonego faktu, tak aby mógł zostać zidentyfikowany przez oprogramowanie komputerowe, przy czym taksonomie definiują tagi, które mają być używane dla każdego zgłaszanego pojęcia, nadając danym cyfrowe znaczenie.

Każda koncepcja finansowa jest definiowana jako element o określonych atrybutach, takich jak typ danych, typ okresu i typ salda, ułożonych w hierarchiczne struktury, które ułatwiają logiczne grupowanie i nawigację. System obejmuje wiele baz łączy, które ustanawiają różne relacje między elementami, w tym bazy łączy prezentacji, które definiują sposób prezentacji elementów w raportach finansowych, bazy łączy obliczeń, które określają relacje matematyczne, oraz bazy łączy definicji, które zapewniają relacje koncepcyjne.

Oto przykład pliku instancji **IFRS XBRL dla sklepu e-commerce opartego na SaaS**, który wykorzystuje realistyczne elementy, takie jak *Przychody z umów z klientami*, *Koszty rozwoju oprogramowania*, *Koszty hostingu* i *Przychody odroczone*. Ten przykład jest zgodny ze strukturą instancji XBRL 2003 z taksonomią IFRS GP 2005:

```
<?xml version="1.0" encoding="UTF-8"?>

<xbrli:xbrl
    xmlns:ifrs-gp="http://xbrl.iasb.org/int/fr/ifrs/gp/2005-05-15"
    xmlns:iso4217="http://www.xbrl.org/2003/iso4217"
    xmlns:xbrli="http://www.xbrl.org/2003/instance"
    xmlns:xbrll="http://www.xbrl.org/2003/linkbase"
    xmlns:xlink="http://www.w3.org/1999/xlink">

    <xbrll:schemaRef
xlink:href="http://www.example.com/xbrl/taxonomy/saas"
```

```
xlink:type="simple"/>

  <ifrs-gp:Przychody contextRef="FY2024" unitRef="EUR"
decimals="0">124000000</ifrs-gp:Przychody>
    <ifrs-gp:Koszty sprzedaży contextRef="FY2024" unitRef="EUR"
decimals="0">42000000</ifrs-gp:Koszty sprzedaży>
    <ifrs-gp:Wydatki na badania i rozwój contextRef="FY2024"
unitRef="EUR" decimals="0">18000000</ifrs-gp:Wydatki na badania i
rozwój>
    <ifrs-gp:Wydatki ogólne i administracyjne contextRef="FY2024"
unitRef="EUR" decimals="0">12000000</ifrs-gp:Wydatki ogólne i
administracyjne>
    <ifrs-gp:Przychody odroczone contextRef="FY2024" unitRef="EUR"
decimals="0">30000000</ifrs-gp:Przychody odroczone>
    <ifrs-gp:InneDochodyOperacyjne contextRef="FY2024" unitRef="EUR"
decimals="0">2500000</ifrs-gp:InneDochodyOperacyjne
  <ifrs-gp:InneKosztyOperacyjne contextRef="FY2024" unitRef="EUR"
decimals="0">1600000</ifrs-gp:InneKosztyOperacyjne>
    <ifrs-gp:ZyskStrata contextRef="FY2024" unitRef="EUR"
decimals="0">48300000</ifrs-gp:ZyskStrata>

    <xbrli:context id="FY2024">
      <xbrli:entity>
            <xbrli:identifier
scheme="http://www.example.com/xbrl/entity">SAASSHOP</xbrli:identifier
>
      </xbrli:entity>
        </xbrli:period>
          <xbrli:startDate>2024-01-01</xbrli:startDate>
          <xbrli:endDate>2024-12-31</xbrli:endDate>
      </xbrli:period>
    </xbrli:context>

    <xbrli:unit id="EUR">
        <xbrli:measure>iso4217:EUR</xbrli:measure>
    </xbrli:unit>

</xbrli:xbrl>
```

Taksonomie XBRL pokazują, w jaki sposób złożone informacje finansowe można przekształcić z formatów narracyjnych w ustrukturyzowane, czytelne dla maszyn formaty, które zachowują znaczenie semantyczne, umożliwiając jednocześnie precyzyjną analizę obliczeniową. Standaryzowane ramy zapewniają, że dane finansowe są spójnie kategoryzowane i rozumiane w różnych systemach i przez interesariuszy, umożliwiając bezproblemową wymianę i porównywalność danych.

Język znaczników produktów finansowych (FpML)

FpML stanowi kolejny przykład matematycznej strukturyzacji dla wymiana informacji biznesowych. Jako standard wymiany informacji biznesowych oparty na Extensible Markup Language (XML), FpML umożliwia transakcje typu business-to-business pozagiełdowymi instrumentami pochodnymi online, zgodnie ze standardami W3C. Standard obejmuje podstawowe procesy, w tym handel, wycenę, potwierdzenie, nowację, zwiększenie, zmianę, zakończenie, alokację, raportowanie pozycji i dopasowywanie przepływów pieniężnych.

Poniżej możesz zobaczyć przykład Dokument FpML (Financial products Markup Language) reprezentujący **swap stóp procentowych** między dwoma kontrahentami. Ten przykład pokazuje kluczowe elementy struktury FpML 5.x, uproszczone dla czytelności.

```
<?xml version="1.0" encoding="UTF-8"?>

<fpml:trade
    xmlns:fpml="http://www.fpml.org/FpML-5/confirmation"
    xmlns:xsi="http://www.w3.org/2001/XMLSchema-instance"
    xsi:schemaLocation="http://www.fpml.org/FpML-5/confirmation
https://www.fpml.org/spec/fpml-5-10-4-wd-1/xsd/confirmation/fpml-main-
5-10.xsd">

    <fpml:tradeHeader>
        <fpml:partyTradeIdentifier>
            <fpml:partyReference href="Party1"/>
            <fpml:tradeId
tradeIdScheme="http://www.saasfx.com/trade-id">SWAP123456</fpml:tradeI
d>
        </fpml:partyTradeIdentifier>
        <fpml:partyTradeIdentifier>
```

```
            <fpml:partyReference href="Party2"/>
            <fpml:tradeId
tradeIdScheme="http://www.tradereportinghub.com/trade-id">SWAP987654</
fpml:tradeId>
        </fpml:partyTradeIdentifier>
        <fpml:tradeDate>2025-06-10</fpml:tradeDate>
    </fpml:tradeHeader>

    <fpml:swap>
        <fpml:swapStream>
            <fpml:payerPartyReference href="Party1"/>
            <fpml:receiverPartyReference href="Party2"/>
            <fpml:calculationPeriodDates>
                <fpml:effectiveDate>

<fpml:unadjustedDate>2025-06-12</fpml:unadjustedDate>
                </fpml:effectiveDate>
                <fpml:terminationDate>

<fpml:unadjustedDate>2028-06-12</fpml:unadjustedDate>
                </fpml:terminationDate>
            </fpml:calculationPeriodDates>
            <fpml:paymentDates>
                <fpml:paymentFrequency>
                    <fpml:periodMultiplier>6</fpml:periodMultiplier>
                    <fpml:period>M</fpml:period>
                </fpml:paymentFrequency>
            </fpml:paymentDates>
            <fpml:calculationPeriodAmount>
                <fpml:notionalSchedule>
                    <fpml:notionalStepSchedule>

<fpml:initialValue>10000000</fpml:initialValue>
                        <fpml:currency>EUR</fpml:currency>
                    </fpml:notionalStepSchedule>
                </fpml:notionalSchedule>
                <fpml:calculation>
                    <fpml:fixedRateSchedule>
```

```
                        <fpml:initialValue>0.015</fpml:initialValue>
                    </fpml:fixedRateSchedule>

<fpml:dayCountFraction>30/360</fpml:dayCountFraction>
                </fpml:calculation>
            </fpml:calculationPeriodAmount>
        </fpml:swapStream>

        <fpml:swapStream>
            <fpml:payerPartyReference href="Party2"/>
            <fpml:receiverPartyReference href="Party1"/>
            <fpml:calculationPeriodDates>
                <fpml:effectiveDate>

<fpml:unadjustedDate>2025-06-12</fpml:unadjustedDate>
                </fpml:effectiveDate>
                <fpml:terminationDate>

<fpml:unadjustedDate>2028-06-12</fpml:unadjustedDate>
                </fpml:terminationDate>
            </fpml:calculationPeriodDates>
            <fpml:paymentDates>
                <fpml:paymentFrequency>
                    <fpml:periodMultiplier>6</fpml:periodMultiplier>
                    <fpml:period>M</fpml:period>
                </fpml:paymentFrequency>
            </fpml:paymentDates>
            <fpml:calculationPeriodAmount>
                <fpml:notionalSchedule>
                    <fpml:notionalStepSchedule>

<fpml:initialValue>10000000</fpml:initialValue>
                        <fpml:currency>EUR</fpml:currency>
                    </fpml:notionalStepSchedule>
                </fpml:notionalSchedule>
                <fpml:calculation>
                    <fpml:floatingRateCalculation>
                        <fpml:floatingRateIndex>EUR-
```

```
EURIBOR-6M</fpml:floatingRateIndex>
                        <fpml:indexTenor>

<fpml:periodMultiplier>6</fpml:periodMultiplier>
                            <fpml:period>M</fpml:period>
                        </fpml:indexTenor>
                    </fpml:floatingRateCalculation>

<fpml:dayCountFraction>ACT/360</fpml:dayCountFraction>
                </fpml:calculation>
            </fpml:calculationPeriodAmount>
        </fpml:swapStream>
    </fpml:swap>

    <fpml:party id="Party1">
        <fpml:partyId>saasfx-ltd</fpml:partyId>
        <fpml:partyName>SaaS FX Ltd</fpml:partyName>
    </fpml:party>
    <fpml:party id="Party2">
        <fpml:partyId>capitalbank-ag</fpml:partyId>
        <fpml:partyName>CapitalBank AG</fpml:partyName>
    </fpml:party>

</fpml:trade>
```

Dzięki wykorzystaniu znanego standardu XML, FpML staje się stosunkowo łatwy do zrozumienia i wdrożenia przez programistów. Norma obejmuje formalną definicję ról stron i mechanizmów powiadamiania o transakcjach, tworząc kompleksowe ramy matematyczne do reprezentowania transakcji pochodnych. Ta standaryzacja eliminuje niejednoznaczność i umożliwia precyzyjne przetwarzanie obliczeniowe złożonych relacji finansowych.

Wizualne i analityczne ramy biznesowe

Struktura matematyczna Business Model Canvas

Business Model Canvas (BMC) zapewnia systematyczne ramy do reprezentowania modeli biznesowych. Płótno składa się z dziewięciu bloków

konstrukcyjnych, które reprezentują kluczowe aspekty modeli biznesowych: segmenty klientów, propozycje wartości, kanały, relacje z klientami, strumienie przychodów, kluczowe zasoby, kluczowe działania, kluczowe partnerstwa i struktura kosztów. Każdy blok reprezentuje określony wymiar modelu biznesowego ze zdefiniowanymi relacjami i zależnościami. Podobnie jest w przypadku Lean Canvas i opisywałem różnice między LC i BMC w przeszłości.

Chociaż oba są strukturami danych wizualnych (nie matematycznych per se), ich potencjał tkwi w systematycznym rozkładzie modeli biznesowych na dyskretne, mierzalne komponenty. Każdy z bloków można przedstawić jako dane tekstowe ze specyficznymi atrybutami, relacjami i ograniczeniami (więc zasadniczo, aby uczynić je bardziej kompleksowymi przez AI, należy dodać do nich nieco więcej warstw relacji). Segmenty klientów można zdefiniować matematycznie za pomocą zmiennych demograficznych, behawioralnych i preferencji. Propozycje wartości można skwantyfikować za pomocą metryk korzyści i obliczeń wartości klienta. Strumienie przychodów można wyrazić za pomocą wzorów matematycznych odnoszących się do modeli cenowych, prognoz wolumenu i struktur kosztów.

Wizualna struktura BMC może być potencjalnie wykorzystana jako dane wejściowe (np. jako obraz) do przetworzenia przez AI. Chociaż używając image ryzykujesz kilka rzeczy:

1. sztuczna inteligencja ma trudniej zinterpretować image niż dane strukturalne, więc spodziewaj się pewnych zniekształceń danych lub półprawd
2. trudniej jest odtworzyć wszystkie relacje między elementami i konkretnymi danymi finansowymi na image (takimi jak demografia lub relacja między klientem a kanałem). A im bardziej skomplikowany image, tym więcej AD1.

Zamiast tego możesz przetłumaczyć te tabelaryczne dane na XML lub JSON. Taka przekształcona struktura danych modelu BMC mogłaby wyglądać następująco:

```
{
  "businessModelCanvas": {
    "customerSegments": [
      {
        "id": "cs1",
        "name": "Entrepreneurs who want to build SaaS software",
        "type": "primary_target"
      }
```

```
],
"valuePropositions": [
  {
    "id": "vp1",
    "name": "Help with learning (workshops, blog)",
    "targetSegments": ["cs1"],
    "type": "educational_support"
  },
  {
    "id": "vp2",
    "name": "MVP for early users",
    "targetSegments": ["cs1"],
    "type": "product_development"
  },
  {
    "id": "vp3",
    "name": "User-Based Development",
    "targetSegments": ["cs1"],
    "type": "custom_development"
  }
],
"channels": [
  {
    "id": "ch1",
    "name": "Google Search Results",
    "type": "digital_marketing",
    "relatedActivities": ["ka1"]
  },
  {
    "id": "ch2",
    "name": "LinkedIn",
    "type": "social_media",
    "relatedRelationships": ["cr2"]
  }
],
"customerRelationships": [
  {
    "id": "cr1",
```

```
      "name": "Direct contact after clicking Contact Us",
      "type": "direct_support",
      "channels": ["ch1"]
    },
    {
      "id": "cr2",
      "name": "Direct contact through LinkedIn",
      "type": "social_engagement",
      "channels": ["ch2"]
    }
  ],
  "revenueStreams": [
    {
      "id": "rs1",
      "name": "Maintenance of existing systems",
      "type": "recurring_revenue",
      "relatedActivities": ["ka2"]
    },
    {
      "id": "rs2",
      "name": "Per-Hour Development",
      "type": "service_revenue",
      "relatedActivities": ["ka2"]
    }
  ],
  "keyResources": [
    {
      "id": "kr1",
      "name": "Stable Server Architecture",
      "type": "technological",
      "supportedActivities": ["ka1", "ka2"]
    },
    {
      "id": "kr2",
      "name": "Experienced Developers",
      "type": "human",
      "supportedActivities": ["ka2"],
      "relatedCosts": ["co2"]
```

```
    }
  ],
  "keyActivities": [
    {
      "id": "ka1",
      "name": "Automat Deployment (CI/CD)",
      "type": "technological_process",
      "requiredResources": ["kr1"],
      "supportedValueProps": ["vp2"]
    },
    {
      "id": "ka2",
      "name": "Development",
      "type": "core_service",
      "requiredResources": ["kr1", "kr2"],
      "supportedValueProps": ["vp2", "vp3"],
      "generatesRevenue": ["rs1", "rs2"]
    }
  ],
  "keyPartnerships": [
    {
      "id": "kp1",
      "name": "Some Strategic Partner",
      "type": "strategic_alliance",
      "purpose": "business_expansion"
    },
    {
      "id": "kp2",
      "name": "Some Strategic Client",
      "type": "key_customer",
      "purpose": "revenue_generation",
      "relatedRevenue": ["rs1", "rs2"]
    }
  ],
  "costStructure": [
    {
      "id": "co1",
      "name": "Server structure",
```

```
        "type": "infrastructure_cost",
        "relatedResources": ["kr1"]
      },
      {
        "id": "co2",
        "name": "Salaries",
        "type": "personnel_cost",
        "relatedResources": ["kr2"]
      },
      {
        "id": "co3",
        "name": "Accounting",
        "type": "operational_cost"
      }
    ],
    "businessModelType": "B2B Service Provider",
    "legend": {
      "cashflow": "teal",
      "clientEntrepreneurs": "yellow"
    },
    "relationships": {
      "valueChain": {
        "from": "customerSegments",
        "through": ["valuePropositions", "channels",
"customerRelationships"],
        "to": "revenueStreams"
      },
      "operationalChain": {
        "from": "keyResources",
        "through": "keyActivities",
        "to": "valuePropositions"
      },
      "costRevenueLinkage": {
        "costs": ["co1", "co2", "co3"],
        "revenues": ["rs1", "rs2"],
        "profitability": "dependent_on_efficiency"
      }
    }
```

```
  }
}
```

Należy zauważyć, że nie jest to w żaden sposób ustandaryzowane. W przypadku prostego zastosowania AI powinno być zrozumiałe, ale jeśli myślisz o szerszym zastosowaniu (takim jak automatyczne raportowanie danych między działami i przedstawianie relacji między nimi), prawdopodobnie dobrym pomysłem byłoby udokumentowanie całej struktury.

Wyobraź sobie możliwości, które przekładają się na zdolność LLM do przetwarzania bardziej efektywnie niż narracyjne plany biznesowe. Połączona natura dziewięciu bloków tworzy reprezentację, którą można wyrazić logicznie, umożliwiając obliczeniową analizę wykonalności modelu biznesowego, możliwości optymalizacji i strategicznych alternatyw.

Zrównoważona karta wyników jako ramy matematyczne

Zrównoważona karta wyników (BSC) reprezentuje podejście do pomiaru efektywności strategii biznesowej, które wykracza poza tradycyjne wskaźniki finansowe i jest szeroko stosowane przez menedżerów. Ramka bada organizacje z **czterech różnych perspektyw**:

- Finanse (lub zarządzanie) — na przykład „*Naszym celem jest zwiększenie kwartalnych marż zysku netto o 5% poprzez optymalizację kosztów i strategię cenową.*”
- Klient/Interesariusz — na przykład „*Naszym celem jest poprawa wyników satysfakcji klienta o 10% poprzez zwiększenie czasu reakcji i personalizacji naszego wsparcia.*”
- Proces wewnętrzny — na przykład „*Dzięki automatyzacji naszego przepływu pracy związanego z realizacją zamówień planujemy skrócić czas przetwarzania z 48 do 24 godzin.*”
- Zdolności organizacyjne (nauka i rozwój) — na przykład „*Uruchomimy program ciągłego kształcenia, aby zwiększyć umiejętności cyfrowe pracowników i napędzać innowacje gotowość.*„

Zauważ, jak każdy KPI próbuje **ustalić cel, który jest SMART**!

Każda perspektywa obejmuje cele strategiczne, mierniki wydajności (KPI), cele i inicjatywy, które można matematycznie zdefiniować i śledzić.

Aby uczynić to „matematycznym”, możemy po prostu dodać kilka reguł i punktacji. Na przykład możemy ustalić, że:

- istnieją 4 Perspektywy: Finansowa (F), Klient (C), Proces Wewnętrzny (P), Nauka i Wzrost (L)
- Każda perspektywa ma wagę (znaczenie) i wynik wydajności (0–100)
- Wynik całkowity = ważona suma wyników perspektywy

Tak więc kwartalna tabela wydajności mogłaby wyglądać następująco:

Perspektywa	Waga	Wynik wydajności
Finansowe (F)	0.30	80
Klient (C)	0,25	70
Proces wewnętrzny (P)	0,25	60
Nauka i Wzrost (L)	0,20	90

A stosując prostą algebrę możemy obliczyć **Balanced Scorecard Performance Index = 74,5 / 100**, który można śledzić w czasie lub porównywać między działami/strategiami, aby ilościowo ocenić strategiczną wydajność.

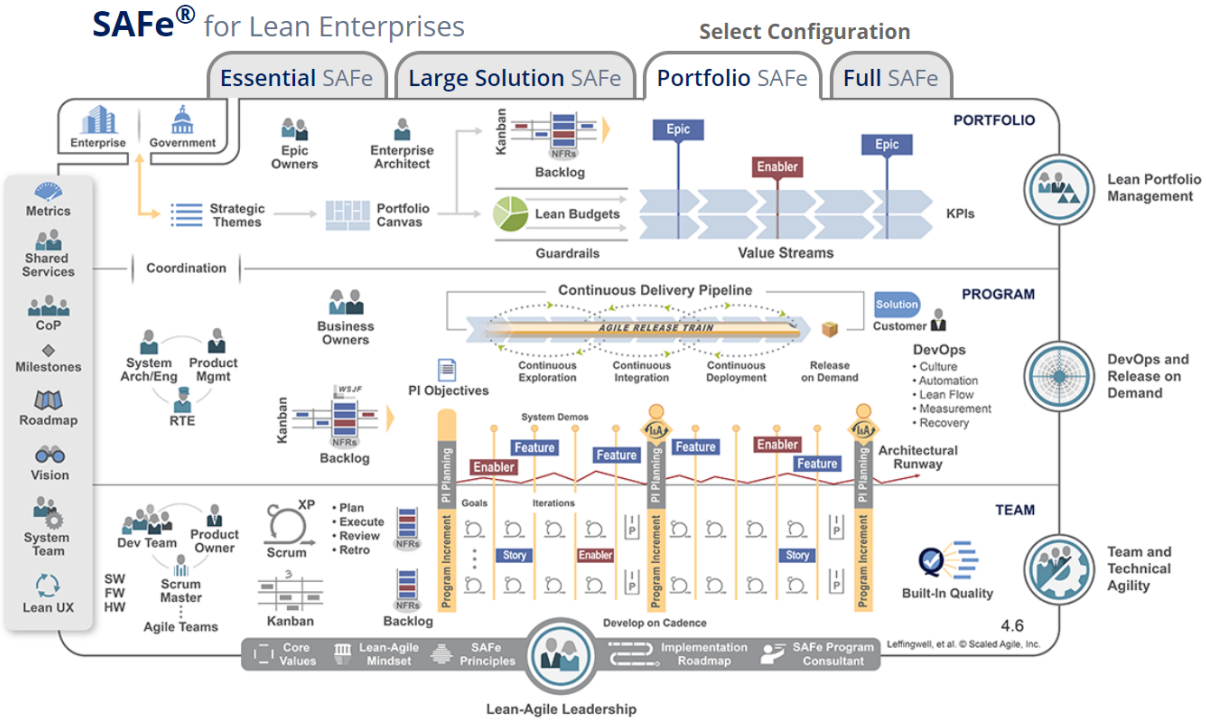
Struktura BSC ułatwia LLM przetwarzanie poprzez systematyczne podejście do pomiaru wydajności i poprzez precyzyjne definicje każdego obiektu. Cele strategiczne są rozbijane na wykonalne kroki, które można skwantyfikować za pomocą określonych KPI, tworząc mierzalne połączenia między abstrakcyjnymi koncepcjami strategicznymi a konkretnymi wskaźnikami operacyjnymi. Takie podejście można wdrożyć jako część EBM (Evidence-Based Management) lub narzędzie dla EBM. Mapy strategii zapewniają wizualną reprezentację logicznych, przyczynowo-skutkowych powiązań między celami strategicznymi, tworząc relacje matematyczne, które można wyrazić jako formalne zależności i sieci wpływów.

Ewolucja BSC w holistyczny system zarządzania strategią pokazuje, w jaki sposób jakościowe koncepcje strategiczne można przekształcić w ilościowe ramy odpowiednie do analizy obliczeniowej. Zdyscyplinowane ramy zapewniają organizacjom sposób na „łączenie kropek” między różnymi komponentami planowania strategicznego i zarządzania, tworząc widoczne połączenia między projektami, pomiarami, celami strategicznymi i misją organizacji, które można modelować matematycznie.

SAFe dla przedsiębiorstw Lean

Chociaż nie jest to model matematyczny według projektu, nie byłbym sobą, gdybym nie wspomniał o nim jako entuzjasta Agile. Scaled Agile Framework (SAFe) dla przedsiębiorstw Lean zapewnia **ustrukturyzowane i wysoce zorganizowane podejście do skalowania** praktyk Lean, Agile i DevOps w dużych organizacjach. SAFe opiera się na podstawowych zasadach Lean-Agile, w tym na przyjmowaniu perspektywy ekonomicznej, stosowaniu myślenia systemowego, zakładaniu zmienności przy jednoczesnym zachowaniu opcji, budowaniu przyrostowym z szybkimi cyklami uczenia się i organizowaniu wokół wartości. Zasady te mają na celu kierowanie podejmowaniem decyzji, wspieranie dopasowania i optymalizację dostarczania wartości w złożonych strukturach organizacyjnych.

Architektura SAFe jest zdefiniowana przez cztery hierarchiczne konfiguracje: Essential SAFe, Large Solution SAFe, Portfolio SAFe i Full SAFe — każda z nich oferuje ustandaryzowany zestaw ról, obowiązków i procesów dostosowanych do różnych skal i złożoności biznesu. W swojej istocie SAFe wykorzystuje konstrukcje takie jak Agile Release Trains (ART), strumienie wartości i przyrosty programu, które można przedstawić jako modele matematyczne lub ustrukturyzowane przepływy danych. Te konstrukcje ułatwiają wizualizację i zarządzanie zależnościami, pracą w toku i dostarczaniem wartości, wspierając obiektywną ocenę za pomocą metryk, takich jak czas realizacji, wielkość partii i koszt opóźnienia.



SAFe kładzie nacisk na przejrzystość, wbudowaną jakość i zdecentralizowane podejmowanie decyzji, które można sformalizować w modelach procesów i schematach danych, które są dobrze dostosowane do analizy przez duże modele językowe (LLM) – szczególnie jeśli próbujesz standaryzować dane organizacji w strukturze XML lub JSON. Poprzez definiowanie jasnych relacji między zespołami, strumieniami wartości i inicjatywami na poziomie portfela, SAFe umożliwia organizacjom reprezentowanie strategii, realizacji i finansów w sposób ustrukturyzowany, czytelny dla maszyn. Ta matematyczna rygorystyczność, w połączeniu z naciskiem na ciągłe doskonalenie i dostosowanie, sprawia, że SAFe jest potężnym szablonem zarówno dla ludzkiego, jak i napędzanego przez sztuczną inteligencję rozumienia organizacji i wydajności przedsiębiorstwa.

Podejścia do modelowania procesów i systemów

Modele procesów biznesowych Petri Net

Sieci Petriego zapewniają formalne ramy matematyczne do modelowania procesów biznesowych. To podejście wykorzystuje dobrze ugruntowaną teorię

przechwytywania i analizowania modeli z współbieżnością, zapewniając precyzyjną semantykę, która czyni je idealnym do wyjaśniania podstawowych pojęć i umożliwiania analizy obliczeniowej. Formalna metoda oferuje wyraźne zalety w modelowaniu procesów w porównaniu z przemysłowymi językami modelowania stosowanymi w innych podejściach.

Matematyczne podstawy sieci Petriego sprawiają, że nadają się one do przetwarzania LLM, ponieważ zapewniają formalne definicje stanów procesów, przejść i warunków. Precyzyjna semantyka umożliwia obliczeniową weryfikację właściwości procesu, wykrywanie błędów projektowych i analizę zachowania procesu w różnych warunkach. Prostota i ekspresywność sieci Petriego sprawiają, że idealnie nadają się one do reprezentowania złożonych procesów biznesowych w matematycznie rygorystyczny sposób, który można analizować obliczeniowo.

Dynamika systemów dla strategii biznesowej

Dynamika systemów zapewnia matematyczne ramy do modelowania złożonych systemów biznesowych, które uwzględniają pętle sprzężenia zwrotnego, opóźnienia i nieliniowe relacje. To podejście umożliwia organizacjom budowanie modeli, które symulują wpływ różnych zmiennych biznesowych, takich jak popyt klientów, działania marketingowe i ceny, zapewniając jaśniejsze zrozumienie, w jaki sposób strategie krótkoterminowe i długoterminowe wpływają na wydajność. W przeciwieństwie do modeli statycznych lub liniowych, System Dynamics **uwzględnia pętle sprzężenia zwrotnego i opóźnienia**, dzięki czemu jest bardziej odpowiedni dla złożonych, rzeczywistych środowisk biznesowych. To podejście sprawia również, że jest bardziej odpowiedni dla szybko zmieniających się firm lub firm działających w zmiennym środowisku.

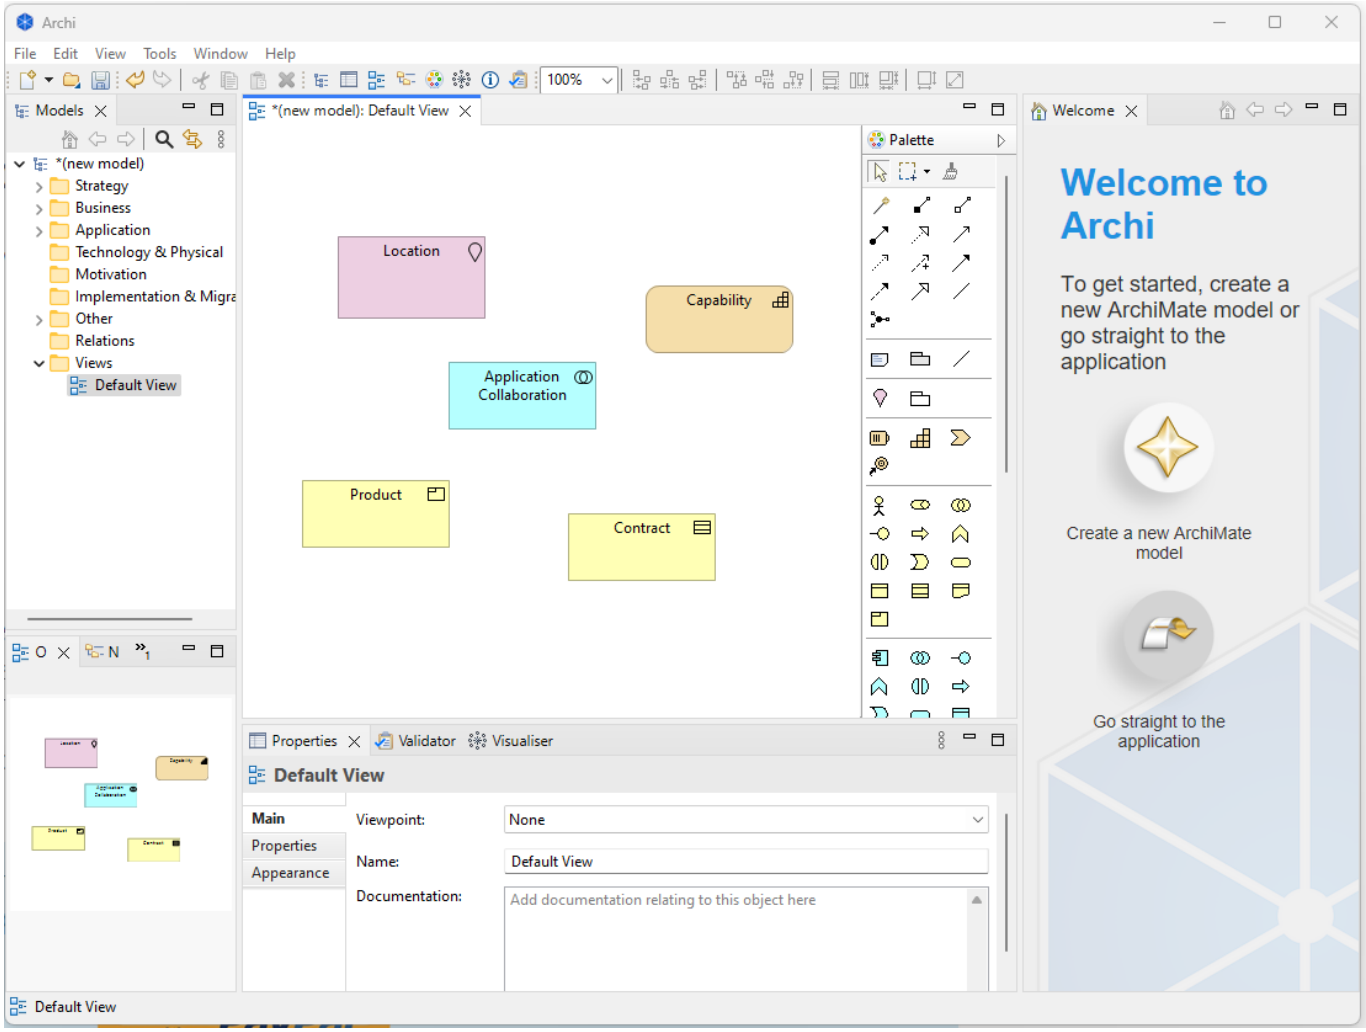
Matematyczna natura dynamiki systemów sprawia, że jest ona w wysokim stopniu kompatybilna z przetwarzaniem LLM, ponieważ przekształca jakościowe relacje biznesowe w ilościowe równania różniczkowe i struktury sprzężenia zwrotnego. Podejście to identyfikuje trzy podstawowe zachowania klientów jako główne czynniki wpływające na wyniki biznesowe: **pozyskiwanie klientów, retencja i wzrost wskaźników zakupów**, z których każdy można modelować matematycznie przy użyciu określonych zmiennych i relacji. Struktura umożliwia modelowanie elastyczności cenowej, dynamiki lejka marketingowego i zarządzania cyklem życia produktu za pomocą reprezentacji matematycznych, które odzwierciedlają złożone współzależności.

Struktury i narzędzia graficzne

ArchiMate Enterprise Architecture Framework

ArchiMate to otwarty, niezależny język modelowania przeznaczony dla architektury korporacyjnej. Obsługuje on jasny i spójny opis, analizę i wizualizację architektur w różnych domenach biznesowych. Opracowany jako standard techniczny przez The Open Group, ArchiMate opiera się na zasadach z obecnie wycofanego standardu IEEE 1471, oferując ustrukturyzowane podejście do reprezentowania złożonych systemów przedsiębiorstwa.

ArchiMate zapewnia formalny język modelowania dla architektury przedsiębiorstwa, który tworzy reprezentacje struktury organizacyjnej i relacji. Zapewnia narzędzia wspomagające architektów przedsiębiorstw w opisywaniu, analizowaniu i wizualizacji relacji między domenami biznesowymi w jednoznaczny sposób. Struktura umożliwia modelowanie wysokiego poziomu w obrębie domen i reprezentację relacji między domenami.



Standard obejmuje określone elementy dla warstw biznesowych, aplikacji i technologii, ze zdefiniowanymi relacjami i właściwościami, które można wyrazić matematycznie. Tak więc, chociaż ArchiMate jest narzędziem, a nie strukturą danych, można go używać do eksportowania danych, na przykład do formatu Open Exchange. Eksportowanie danych umożliwia obliczeniową analizę złożoności architektury przedsiębiorstwa, analizę zależności i ocenę wpływu zmian architektonicznych. Ze względu na złożoność programu dobrym pomysłem jest rozpoczęcie od kilku szablonów ArchiMate.

Notacji modelu procesu biznesowego (BPMN)

Notacja modelu procesu biznesowego zapewnia standardowy język wizualny do reprezentowania procesów biznesowych, które można przekształcić w modele

matematyczne odpowiednie do przetwarzania LLM. Diagramy BPMN wykorzystują standardowe symbole dla zadań, zdarzeń, bram i ścieżek, które można przedstawić matematycznie jako maszyny stanowe lub algebry procesów. Standaryzowany format zapewnia spójność i zmniejsza liczbę błędów w mapowaniu procesów, zapewniając jednocześnie uniwersalny język wizualny zarówno dla zespołów biznesowych, jak i technicznych.

To NIE jest to samo, co ArchiMate, ponieważ ArchiMate nie używa BPMN bezpośrednio w ramach własnej notacji, ale oba mogą być —i często są —używane razem. ArchiMate zapewnia kontekst architektoniczny i mapowanie procesów wysokiego poziomu, podczas gdy BPMN dostarcza szczegółowe przepływy procesów. Integracja między nimi umożliwia organizacjom osiągnięcie zarówno nadzoru architektonicznego, jak i szczegółów operacyjnych.

Aspekt	**ArchiMate**	**BPMN**
Główny cel	Architektura przedsiębiorstwa (wysokiego poziomu)	Szczegółowe modelowanie procesów biznesowych
Modelowanie procesów	Abstrakcyjny, wysokiego poziomu (tylko istnienie)	Szczegółowy, krok po kroku przepływ
Integracja	Można połączyć się z BPMN w celu uzyskania szczegółów	Można odwołać się do ArchiMate
Typowy przypadek użycia	Architekci, planowanie strategiczne	Analitycy procesów, projektowanie przepływu pracy

Formalna struktura BPMN sprawia, że jest ona w wysokim stopniu kompatybilna z przetwarzaniem LLM **(po wyeksportowaniu grafu do ustrukturyzowanych danych),** ponieważ każdy typ elementu ma zdefiniowaną semantykę i zachowanie, które można modelować matematycznie. Przepływy procesów można przedstawić jako skierowane grafy z węzłami reprezentującymi działania i krawędziami reprezentującymi przejścia, umożliwiając obliczeniową analizę wydajności procesów, wąskich gardeł i możliwości optymalizacji.

Rozważania na temat implementacji i struktury

schematów

Schemat JSON dla danych biznesowych

Schemat JSON zapewnia potężne ramy do tworzenia ustrukturyzowanych, maszynowo czytelne reprezentacje danych biznesowych, które są wyjątkowo dobrze przystosowane do przetwarzania LLM. System schematów umożliwia formalne definiowanie struktur danych, reguł walidacji i relacji, które mogą reprezentować różne domeny biznesowe, w tym adresy, zapisy finansowe, profile użytkowników i struktury organizacyjne. Elastyczność schematu JSON umożliwia dynamiczny wybór schematu na podstawie określonych kontekstów biznesowych, dzięki czemu można go dostosować do różnych potrzeb modelowania biznesowego.

Matematyczna precyzja schematu JSON sprawia, że jest on idealny do przetwarzania LLM, ponieważ zapewnia formalne definicje typów danych, ograniczeń i relacji. Schematy mogą wymuszać określone reguły biznesowe poprzez ograniczenia walidacyjne, zapewniając spójność danych i umożliwiając automatyczne przetwarzanie. Hierarchiczna natura schematu JSON umożliwia reprezentację złożonych relacji biznesowych przy jednoczesnym zachowaniu wydajności obliczeniowej.

XML dla przetwarzania biznesowego

Ustrukturyzowane dane XML są wysoce skuteczne w reprezentowaniu relacji w kontekście biznesowym, dzięki czemu doskonale nadają się do przetwarzania AI. Hierarchiczny format oparty na tagach umożliwia jasne i wyraźne definiowanie jednostek, atrybutów i ich współzależności, umożliwiając maszynom interpretowanie złożonych struktur biznesowych i przepływów pracy z precyzją. Samoopisująca natura XML zapewnia, że kontekstowe metadane są osadzone bezpośrednio w danych, co zwiększa zrozumienie semantyczne i interoperacyjność między systemami. Gdy jest używany jako podstawa dla aplikacji AI — zwłaszcza tych obejmujących ekstrakcję wiedzy, rozumowanie oparte na regułach lub dopasowanie ontologii — XML zapewnia spójną i czytelną dla maszyn strukturę, która obsługuje dokładną interpretację, walidację i integrację logiki biznesowej i relacji.

Magazynowanie wektorowe dla lepszego przetwarzania AI

Magazynowanie wektorowe to idealne rozwiązanie do przechowywania danych

biznesowych, które muszą zostać przetworzone przez AI i duże modele językowe (LLM), ponieważ umożliwia wydajne przetwarzanie niestrukturalnych lub półstrukturalnych informacji, takich jak dokumenty, wiadomości e-mail, interakcje z klientami i bazy wiedzy. Dzięki konwersji tych danych na wielowymiarowe osadzenia wektorowe magazynowanie wektorowe umożliwia szybkie i dokładne wyszukiwanie semantyczne, dopasowywanie podobieństw i rozumienie kontekstowe — kluczowe możliwości dla aplikacji opartych na LLM. To podejście obsługuje bardziej inteligentne zapytania, generowanie rozszerzone o wyszukiwanie (RAG) i zaawansowaną analitykę, co czyni je szczególnie cennym w przypadkach użycia, takich jak automatyzacja obsługi klienta, odkrywanie wiedzy i spersonalizowane rekomendacje w środowiskach biznesowych.

Takie medium może być również używane jako medium uzupełniające do domyślnego opisu procesu biznesowego, więc nie należy go niedoceniać, ponieważ może znacznie poprawić ogólne wyniki i symulować jakość.

Wnioski i jak zacząć

Transformacja jakościowych informacji biznesowych w matematycznie ustrukturyzowane, maszynowo czytelne formaty stanowi krytyczną ewolucję w modelowaniu biznesowym, która znacznie poprawia Możliwości przetwarzania LLM. Badane ramy demonstrują różne podejścia do tej transformacji, od modeli ontologicznych, takich jak BMO i FIBO, które zapewniają formalne podstawy semantyczne, po ustrukturyzowane formaty danych, takie jak XBRL i FpML, które umożliwiają precyzyjne modelowanie finansowe, po ramy analityczne, takie jak BSC i System Dynamics, które kwantyfikują relacje strategiczne. Więc możesz już zauważyć, że użycie jednej metody nie wyklucza użycia innej metody, a dane eksportowane z różnych modeli mogą dać AI różne perspektywy biznesu, co w rezultacie powinno ulepszyć cyfrowy model biznesowy.

Chociaż brzmi to jak skomplikowana sprawa, która wymaga dużo czasu, obecnie z pomocą narzędzi AI możesz rozpocząć analizę biznesową wcześnie. Być może dobrym punktem wyjścia byłoby przepisanie SAFe lub Business Model Canvas do XML lub JSON, a następnie ulepszenie modelu poprzez dalsze definiowanie relacji między obiektami, a następnie przesłanie wiadomości e-mail, danych finansowych i komunikacji do bazy danych wektorowych. Takie przygotowanie nie da ci pełnego „cyfrowego bliźniaka”, ale może być wykorzystane do dalszej poprawy twojego modelu biznesowego, zapytaj LLM o strategię lub o to, jak niektóre niedawne (lub

wyobrażone) wydarzenia mogą wpłynąć na twój biznes. Miejmy nadzieję, że nawet próby zrobienia tego doprowadzą do **twojego** lepszego zrozumienia twojego biznesu i relacji w biznesie, co pomoże ci ułatwić i ulepszyć twój biznes jako całość.