



**Software Engineering
in der industriellen Praxis
(SEIP)**

Dr. Ralf S. Engelschall

Data Structure Types	Data Evolution Approaches	Data Store Types
<p>Scalar, Atom, Primitive Type</p> <p>Plain integer or real number, single character or character string, not indexed and (for string only) accessed in O(1) by character position.</p>	<p>In-Place Editing</p> <p>Modify data through direct in-place editing, overwriting the previous revision.</p>	<p>Key-Value Store</p> <p>Storage of values in an unordered manner, indexed and queried by key.</p> <p>Redis, Riak, Memcached, BigTable, LevelDB</p>
<p>Tuple, Object, Structural Type, Record</p> <p>Ordered, fixed-size sequence of scalar elements, each of individual type, indexed by name and accessed in O(1) by element name.</p>	<p>Stacking Revisions</p> <p>Modify data through stacking revisions, preserving all previous revisions. Latest revision is always on top of stack.</p>	<p>Large-Object Store</p> <p>Storage of unstructured binary-large object (BLOB) data and its associated meta-data, indexed and queried by unique id.</p> <p>Minio, S3, Azure, S3</p>
<p>Sequence, Array, List</p> <p>Ordered sequence of elements, each of same type, indexed by position and accessed in O(1) or O(n) by element position.</p>	<p>Structural Difference</p> <p>Modify data through merging, journaled domain-unspecific structural differences.</p>	<p>Triple Store</p> <p>Storage of subject-predicate-object triples, indexed and queried by subject/predicate/object values and example triples.</p> <p>Redshift, Virtuoso</p>
<p>Set, Bag, Bucket</p> <p>Unordered set of elements, each of same type, not indexed and accessed in O(1) or O(n) by element reference.</p>	<p>Operational Transformation (OT)</p> <p>Modify data through applying journaled, domain-specific operational transformations.</p>	<p>File-Tree Store</p> <p>Storage of unstructured data as named files in a directory tree, indexed and queried by name path from root directory to leaf file.</p> <p>ZFS, XFS, UFS2, APFS</p>
<p>Map, Hash, Associative Array</p> <p>Unordered sequence of elements, each of same type, indexed by (scalar) key and accessed in O(1) by key.</p>	<p>Data Sharing Approaches</p>	<p>Document Store</p> <p>Storage of structured "documents", indexed by id and key/value fields and queried by id and example documents.</p> <p>MongoDB, CouchDB, PostgreSQL</p>
<p>Graph, Nodes & Edges</p> <p>Unordered set of linked elements (nodes), each of individual type, indexed by (scalar) key and accessed in O(1) by key or by following a directed link (edge).</p>	<p>Event Sourcing & CRDT</p> <p>Share data as a chronological sequence of data change events from which the data states can be (re)constructed. Optionally, use a Conflict-Free Replicated Data-Type (CRDT) protocol for the change events.</p>	<p>Full-Text Store</p> <p>Storage of unstructured text, indexed and queried by content words.</p> <p>ElasticSearch, Solr, Scrapy</p>
	<p>Ref-Counting & Copy-on-Write</p> <p>Share data between resources by using reference-counted data chunks, duplicating a chunk (and resetting its reference count to one) on write operations only and destroying a chunk once the reference count drops to zero.</p>	<p>Wide-Column Store</p> <p>Distributed storage of rows of sparse (often untyped) value columns, indexed and queried by column values.</p> <p>PostgreSQL, MongoDB, SQLite, H2, Oracle, EDB, IBM DB2</p>
		<p>Time-Series Store</p> <p>Storage of integer or real values (y-axis) of a time-series (x-axis) into a fixed-size storage format in a round-robin manner where older values are increasingly aggregated (leading to lower resolutions at older times) and finally overwritten.</p> <p>InfluxDB, Prometheus, RRDtool</p>
		<p>DataVault Store</p> <p>Long-term historical storage of foreign, arbitrary relational data in a fixed schema of hubs, links and satellites, indexed and queried for analysis and reporting purposes.</p> <p>DataVault 2.0</p>
		<p>Blockchain Store</p> <p>Storage of values in an unordered manner within information blocks which are cryptographically chained through their hash values and distributed in a peer-to-peer way.</p> <p>Ethereum, Quorum, Tezos, Bitcoin, Hyperledger</p>

Der Software Architect unterscheidet nur 6 **Data Structure Types** für Daten-Elemente: **Scalar** (z.B. Integer, String, etc), **Tuple** (ordered fixed-size sequence of Scalars), **Sequence** (ordered sequence of elements), **Set** (unordered set of elements), **Map** (unordered set of elements, each indexed by key) und **Graph** (unordered set of elements, each indexed by key or by following a link between elements). Alle komplexen spezifischen Datenstrukturen in der Praxis sind für den Software Architect nur die Kombination dieser 6 Typen.

Es gibt zahlreiche **Data Evolution Approaches**, mit denen sich Daten über die Zeit verändern können: im einfachsten Fall, **In-Place Editing**, werden Daten einfach direkt geändert. Ein Zugriff auf frühere Stände gibt es hierbei nicht. Soll auf frühere Stände zugegriffen werden können, so kann man **Stacking Revisions** einsetzen, bei dem vor jeder Änderung der gesamte Datensatz zuerst kopiert wird. Damit nicht der gesamte Datensatz kopiert werden muss, wird bei **Structural Difference** nur eine technische Differenz von altem und neuem Datensatz gespeichert. Alternativ können bei **Operational Transformation** die fachlichen Änderungsoperationen als Journal gespeichert werden.

Wird so ein Journal benutzt, um auch Replika der Datensätze aktuell zu halten, spricht man von **Event Sourcing**. Falls das Journal als dem Protokoll von sogenannten **Conflict-Free Replicated Data-Types (CRDT)** aufgebaut ist, lässt sich statt (unidirektionaler) Replikation auch eine (bidirektionale) Synchronisation erzielen. Falls mehrere konkurrierende Prozesse/Threads logisch auf Kopien, aber physikalisch auf denselben Datensätzen operieren, lässt sich mit **Copy-on-Write** und **Reference Counting** ein gemeinsamer Zugriff und der Lebenszyklus der Datensätze dennoch sinnvoll steuern.

Zur Speicherung von Daten in Datenbanken gibt es zahlreiche **Data Store Types**. Diese unterscheiden sich primär in der Art und Flexibilität der Datenstruktur und den gewährten Garantien. Der verbreitetste Typ ist der **Relational/Table Store**. Der eleganteste Typ ist der **Graph Store**. Der bequemste ist der **Document Store**.

Fragen

- 🔍 Nennen sie 3 **Data Evolution Approaches**, die es jeweils erlauben, auf die früheren Stände der Daten zuzugreifen?

Data Guarantees		Data Access		Data Spreading & Aggregation	
CAP (Trade-In) A distributed data store cannot provide more than two out of three guarantees: Consistency (C), Availability (A), Partition-Tolerance (P). So, it has to choose between Consistency (CP) and Availability (AP) when a network partition or failure happens.		Shared Read/Write Shared access to data for both read and write operations. Example: Multiple threads on heap or Master-Master database setup.		Data River (1-to-N) A real-time fan-out replication of data from a single upstream/source data repository to multiple downstream/target data repositories.	
BASE (NoSQL) The semantics (usually of NoSQL systems) of (Basically) (A)vailable, (S)oft state, and (E)ventual consistency. BASE systems favor Availability over Consistency in the CAP-context.		Shared Read / Exclusive Write Shared access to data for read operations and exclusive access (via a single "owning" component) to data for write operations. Example: RDBMS Master-Slave cluster with shared storage.		Data Mart (N-to-1), ODS A massive sized, easily accessible data repository for storing "big data" from many upstream sources in a (real-time and) structured way and with knowing the actual subsequent analysis usage.	
ACID (RDBMS, NewSQL) The four guarantees provided in parallel (usually by RDBMS and NewSQL systems): Atomicity, Consistency, Isolation and Durability. ACID systems usually favor Consistency over Availability in the CAP-context.		Shared Nothing No shared access to data at all for both read and write operations. Example: Leader-Follower setup with RAFT consensus where Leader writes data only.		Data Lake (N-to-1), Cache A massive sized, easily accessible data repository for storing "big data" from many upstream sources in a (real-time) semi-structured way and without knowing the actual subsequent usage.	
Data Access Grouping		Data Consistency		Data Transfer	
Transaction Protect a sequence of operations from interim exceptions by bracketing the operations in a technical transaction (ensuring that either all or none of the operations succeed).		Exclusive Locking (Mutex) Protect data from concurrent access and resulting inconsistencies with a mutual exclusion lock (mutex) which allows just a single peer to access the data at a time.		Replication Continuously stream or regularly copy data from a master system to one or more slave systems in order to either read the data from slave systems faster or have slave systems available as a fallback/backup in case of a failure of the master system.	
Compensation Protect a sequence of operations from interim exceptions by undoing the already succeeded operations through domain-specific compensating (reverse) operations.		Optimistic Locking Protect data from concurrent access and resulting inconsistencies by taking note of a revision number or content hash during read operations and checking that this information has not changed before writing the data.		Synchronization Continuously stream or regularly copy data between multiple master systems and resolve potential concurrent data modification conflicts. This way allow distributed and even disconnected computing.	

Im Bereich der **Data Guarantees** gibt es drei wesentliche Aspekte: Das **CAP** Theorem adressiert den sog. "Trade-In": Man muss sich in der Praxis üblicherweise zwischen Consistency + Partition-Tolerance (CP) oder Availability + Partition-Tolerance (AP) entscheiden. Beides gleichzeitig geht nicht. Bei **BASE**-Systemen favorisiert man üblicherweise AP. Bei einem traditionellen RDBMS mit **ACID** Garantien favorisiert man üblicherweise CP.

Beim **Data Access Grouping** kennt man **Transaction** und **Compensation**. Ersteres ist eine "technische Klammer", die einem erlaubt, in Fehlerfall wieder zu dem früheren Zustand zurückzukehren. Letzteres ist eine "fachliche Klammer", bei der sog. Kompensationsoperationen einem erlauben die früheren Änderungen zu "stornieren", um so einen früheren konsistenten Zustand wiederzuerlangen.

Beim **Data Access** von zwei oder mehr Prozessen/Threads auf die gleichen Daten unterscheidet man die Ansätze **Shared Read/Write** (alle lesen und schreiben dieselben Daten), **Shared Read / Exclusive Write** (alle lesen und nur einer schreibt dieselben Daten) und **Shared Nothing** (alle lesen und schreiben auf die gleichen synchronisierten Daten).

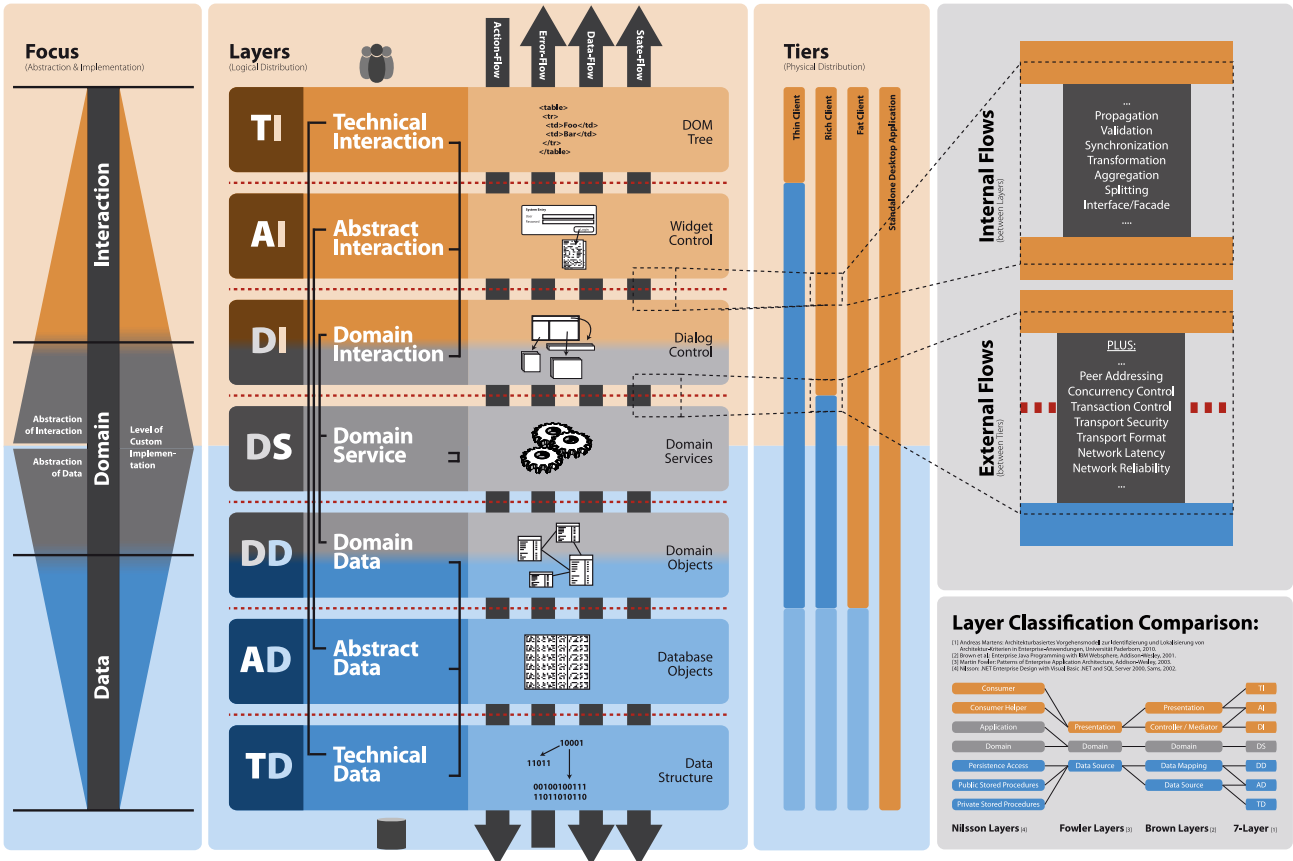
Bei der **Data Consistency** kennt man **Exclusive Locking** (pro Zeiteinheit schreibt nur einer) und **Optimistic Locking** (alle versuchen zu schreiben, erkennen und lösen aber einen Konflikt).

Beim **Data Spreading & Aggregation** unterscheidet man drei Arten: beim **Data River** werden die Daten von einem Master-System auf viele Slave-Systeme repliziert, um u.a. eine höhere Read-Performance zu erzielen. Beim **Data Mart** (strukturierte Daten) und **Data Lake** (semi-strukturierte Daten) werden dagegen die Daten von vielen Master-Systemen auf ein Slave-System repliziert, um u.a. die Daten zentral auswerten oder "cachen" zu können.

Beim **Data Transfer** wird zuletzt noch zwischen der unidirektionalen und konfliktfreien **Replication** und der bidirektionalen und konfliktreichen **Synchronisation** unterschieden.

Fragen

❓ Wie nennt man den Ansatz, bei dem Daten von einem Master-System auf viele Slave-Systeme repliziert werden?



AF 101
 Technical Content: Version 1.0 (2024) | Last Updated: 2024-02-29 | Feedback: [Feedback](#) | License: [License](#)
 Published and Distributed under Creative Commons Attribution-NonCommercial-ShareAlike 4.0 International License
 Published and Distributed under Creative Commons Attribution-NonCommercial-ShareAlike 4.0 International License

In einer Anwendung kann man 7 logische Layer unterscheiden, die jeweils auf zwei Arten gruppiert sind: einerseits gibt es die drei sequenziellen Layer-Gruppen **Technical/Abstract/Domain Interaction**, **Domain Service** und **Domain/Abstract/Technical Data**, andererseits gibt es die drei geschachtelten Layer-Gruppen **Technical Interaction/Data**, **Abstract Interaction/Data** und **Domain Interaction/Service/Data**.

Zusätzlich kann man in einer Anwendung 4 primäre Flüsse unterscheiden: der **Action Flow** läuft konsequent nur von oben nach unten, da alle Aktionen oben vom Benutzer (oder Nachbarsystemen) abgestoßen werden; der **Error Flow** läuft konsequent nur entsprechend in der Gegenrichtung, also von unten nach oben, da Fehler im Worst-Case dem Benutzer gemeldet werden müssen; der (fachliche) **Data Flow** und der (technische) **State Flow** laufen hingegen in beiden Richtungen, da Daten und Zustände sowohl persistiert als auch angezeigt werden müssen.

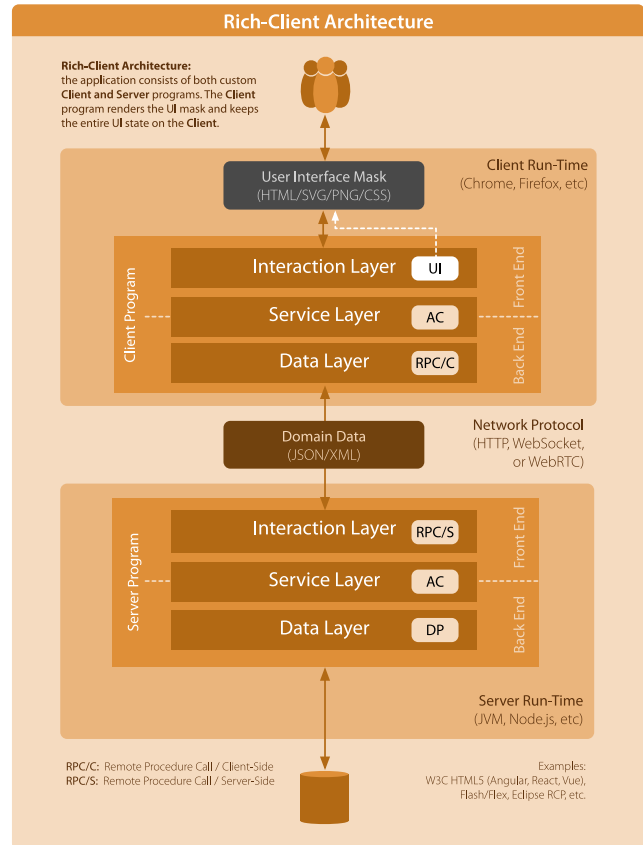
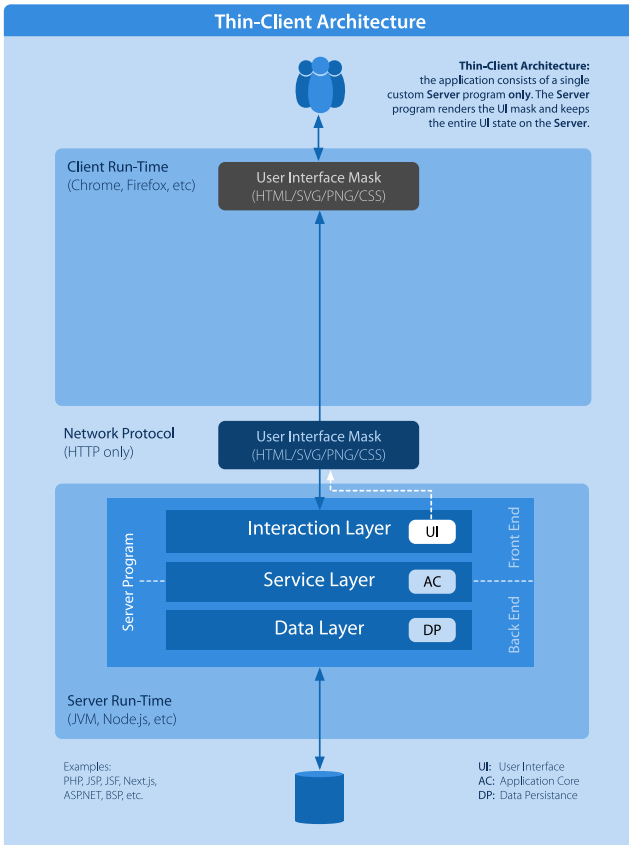
Die Abstraktion bei Interaction/Data in den Layern nimmt von oben/unten zur Mitte hin zu, weshalb auch dort der meiste fachliche Code einer Anwendung geschrieben wird. Für die oberen/unteren Layer wird üblicherweise massiv auf Open Source Libraries/Frameworks gesetzt.

Wenn man statt einem logischen Schnitt (der in einem **Internal Flow** zwischen den Layern resultiert) zwischen zwei Layern einen physikalischen Schnitt macht (der dann in einem **External Flow** resultiert), also die Anwendung in einzelne Programme auf unterschiedlichen Rechnern verteilt, so nennt man die daraus entstehende Architektur nach dem Umfang und der Verantwortung des Clients.

Bei **Thin Client** wird nur die **Technical Interaction** auf den Client ausgelagert, bei **Rich Client** wird die gesamte Benutzeroberfläche (also alle drei Layer **Technical/Abstract/Domain Interaction**) autonom auf den Client ausgelagert (üblicherweise als eine sog. "HTML5 Single-Page-Application"), bei **Fat Client** gibt es gar keinen zugehörigen Server mehr und bei der **Standalone Application** gibt nur noch ein einziges Programm.

Fragen

- ❓ Wie nennt man die Anwendungs-Architektur, bei der die gesamte Benutzeroberfläche autonom auf dem Client läuft, während der Server nur rein fachliche Services liefert?
- ❓ Wie heißen die Web-Anwendungen, welche eine Rich Client Architektur umsetzen?



Bei der **Thin-Client-Architektur** besteht die Anwendung aus nur einem individuellen Server-Programm. Dieses Server-Programm erzeugt die Maske der Benutzeroberfläche und hält den gesamten Zustand der Benutzeroberfläche auf dem Server.

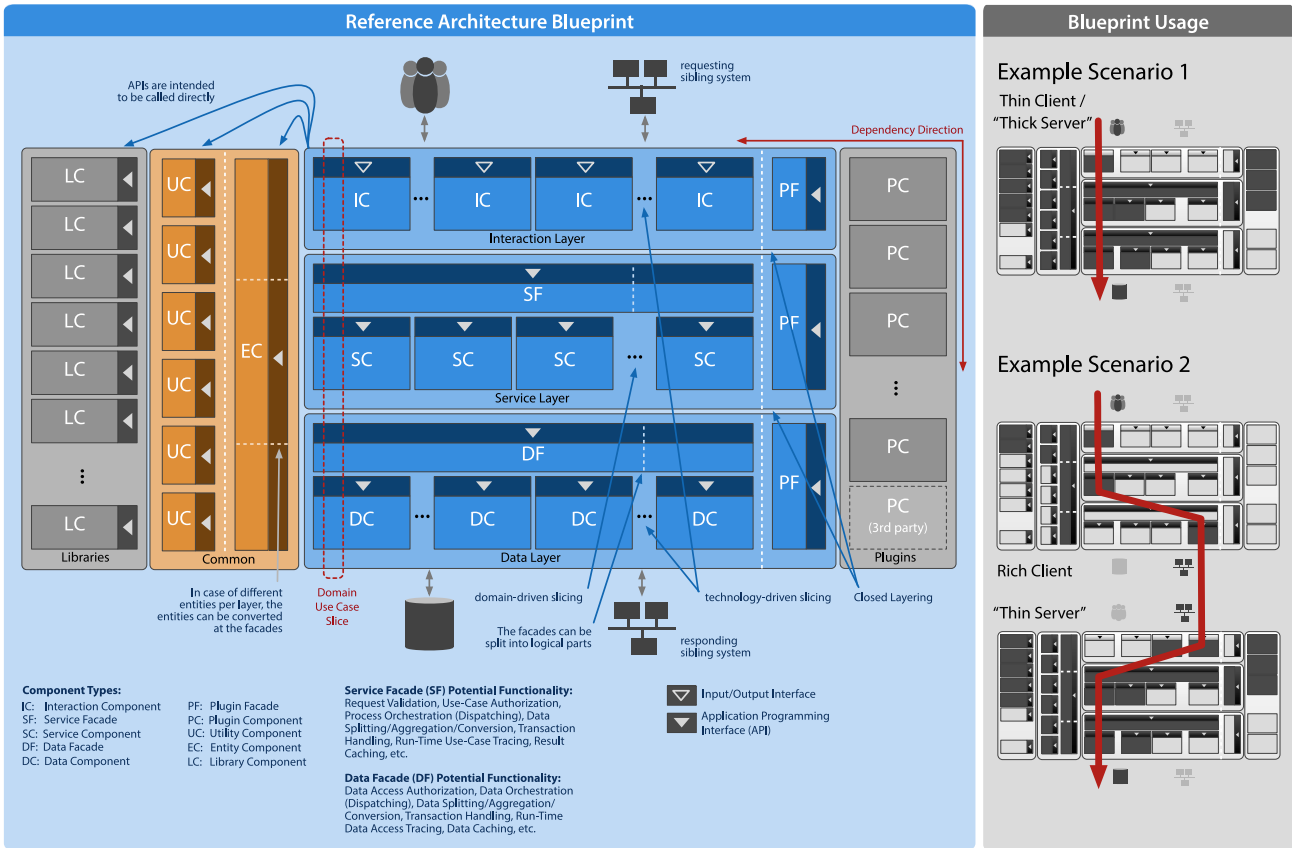
Der Vorteil dieser Architektur ist, daß die Anwendung sehr leicht aktualisiert werden kann. Der Nachteil dieser Architektur ist, daß die Benutzeroberfläche träge reagiert und der Zustand der Benutzeroberflächen aller Clients auf dem Server gehalten werden muss, was den Server zum Flaschenhals werden lassen kann.

Bei der **Rich-Client-Architektur** besteht die Anwendung sowohl aus einem individuellen Client- als auch einem Server-Programm. Das Client-Programm erzeugt die Maske der Benutzeroberfläche und hält den gesamten Zustand der Benutzeroberfläche auf dem Client.

Der Vorteil dieser Architektur ist, daß die Benutzeroberfläche eine hohe Reaktionsfähigkeit zeigt, nur fachliche Daten zwischen Client und Server ausgetauscht werden müssen und der Server weniger stark zum Flaschenhals wird. Der Nachteil dieser Architektur ist, daß gegebenenfalls der Client explizit über eine Installationsprozedur aktualisiert werden muss.

Fragen

- Bei welcher Client-Architektur bietet die Benutzeroberfläche die höhere Reaktionsgeschwindigkeit?



Ein (betriebliches) Informationssystem folgt üblicherweise einer stringenten Komponenten-basierten Referenz-Architektur. Diese wird "full blown" dargestellt und kann beliebig "abgespeckt" werden.

Zuerst besteht diese Referenz-Architektur aus 3 wesentlichen Layern: dem **Interaction Layer** mit den (technisch geschnittenen) Komponenten, welche die I/O-basierten Schnittstellen zum Benutzer (User Interface) und/oder anfragenden Nachbarsystemen (über Network Interface) bereitstellen, dem **Service Layer** mit den (fachlich geschnittenen) Service-Komponenten (auch Anwendungskern genannt) und dem **Data Layer** mit den (technisch geschnittenen) Komponenten, welche die Anbindung an die eigene Datenbank und/oder abzufragenden Nachbarsystemen realisieren.

Man beachte, daß die "Andock-Position" eines Nachbarsystems von seinen Rollen abhängt: wenn es anfragt, dockt es am Interaction Layer an; wenn es abgefragt wird, dockt es am Data Layer an. Wenn es zufällig beide Rollen innehaben sollte, dockt es zweifach an. Die andere Sichtweise ist, daß sowohl der Benutzer als auch die Datenbank als spezielle "Nachbarsysteme" begriffen werden können.

Um die N **Interaction Components** (IC) mit M **Service Components** (SC) zu verbinden, wird üblicherweise eine entkoppelnde **Service Facade** (SF) eingezogen. Aus gleichem Grund gibt es üblicherweise auch eine **Data Facade**.

Das Datenmodell wird in gemeinsame **Entity Components** (EC) ausgelagert. Zusammen mit ggf. gemeinsam genutztem Code lebt beides in einem **Common Slice**. Libraries und Plugins sind ebenfalls in eigene Slices ausgelagert, es gibt aber zwei wesentliche Unterschiede: Libraries sind passiv und bieten der Anwendung ihre Funktionalität über ihre Schnittstellen an. Plugins sind aktiv und steuern die Anwendung, in dem sie sich über Service-Provider Interfaces (SPI) in den **Plugin Facades** in die Anwendung einklinken.

In der Anwendung darf es nur genau eine **Dependency Direction** geben, damit die Anwendung (in der Gegenrichtung der Dependencies) sauber gebaut werden kann. Die Referenz-Architektur wird außerdem üblicherweise zweifach instanziiert, um sowohl einen Rich-Client als auch einen zugehörigen "Thin-Server" daraus zu konstruieren.

Fragen

- ❓ Mit welchem Layer-Pattern werden in einem Informationssystem die **Interaction Components** von den **Service Components** entkoppelt?
- ❓ In welcher Reihenfolge werden die Komponenten einer Anwendung gebaut?

Architecture & Systems

DEF Definition

Reactive System Architecture enables the realization of Reactive Systems.

Reactive Systems are in *subordinated interaction* with their *dominating environment*. They *continuously process endless data streams as small messages*, react at *any time* and respond within *tight time limits*. For this, they *continuously observe their environment* and adapt their *behaviour* to the current situation.

Demand & Deliverables

<p>CTX Context</p> <p>Real-time communication in the context of Digitization, Internet, Internet of Things (IoT), Systems of Engagement, Media and Analytics.</p>	<p>VAL Values</p> <p>Non-blocking input/output data processing, fast responses within tight time limits, and continuous availability of the provided services.</p>
<p>REQ Requirements</p> <p>Services are elastic and provide high scalability, and are resilient and provide high fault tolerance.</p>	<p>PRP Properties</p> <p>Services run fully autonomously, monitor themselves, and automatically adapt to changes in the environment.</p>

Principles

Stay Responsive Always respond in a timely manner.	Accept Uncertainty Build reliability despite unreliable foundations.	Embrace Failure Expect things to go wrong and design for resilience.	Assert Autonomy Design components that act independently and interact collaboratively.	Tailor Consistency Individualize consistency per component to balance availability and performance.	Decouple Time Process asynchronously to avoid coordination and waiting.	Decouple Space Create flexibility by embracing the network.	Handle Dynamics Continuously adapt to varying demand and resources.
--	--	--	--	---	---	---	---

Patterns & Paradigms

<p>ARC Architecture</p> <p>Microservices, Cloud-Native Architecture (CNA), Event-Driven Architecture (EDA).</p>	<p>COM Communication</p> <p>Asynchronous Communication, Non-Blocking I/O, Sequence, Push, Backpressure, Quality of Service (QoS).</p>	<p>DAT Data</p> <p>Semantical Event, Small Message, Endless Stream.</p>	<p>STY Style</p> <p>Functional Programming, Asynchronous Programming.</p> <p>$f(g(x))$</p>
<p>EXE Execution</p> <p>Parallelization, Concurrency, Actors, Threads, Thread-Pool, Event-Loop.</p>	<p>INF Infrastructure</p> <p>Message Queue (MQ), Load Balancer, Reverse Proxy, Service Mesh, Virtual Private Network (VPN).</p>	<p>PRC Processing</p> <p>Complex Event Processing (CEP), EAI Patterns, Stream Processing (map, flatMap, filter, reduce), Event Sourcing.</p>	<p>ASY Asynchronism</p> <p>Callback, Promise/Future, Observable, Publish & Subscribe.</p>

Reactive System Architecture erlaubt die Realisierung von **Reactive Systems**. Reactive Systems sind in **untergeordneter Interaktion** mit ihrer **dominierenden Umgebung**. Sie **verarbeiten kontinuierlich endlose Datenströme** in Form von **kleinen Nachrichten**, reagieren zu **jeder Zeit** und antworten innerhalb **enger Zeitgrenzen**. Dazu **beobachten** sie kontinuierlich ihre **Umgebung** und **passen ihr Verhalten** an die aktuelle Situation an.

Reactive Systems werden primär im Kontext von **Echtzeit-Kommunikation** verwendet, wo Dienste bereitgestellt werden, die **elastisch (elastic)** sein und hohe Skalierbarkeit anbieten müssen und die **verlässlich (reliable)** sein und hohe Fehlertoleranz anbieten müssen.

Fragen

- ❓ Welche zwei wesentlichen Anforderungen erfüllen Reactive Systems?
- ❓ Was charakterisiert Reactive Systems in Bezug auf ihre Datenverarbeitung?