

Česká zemědělská univerzita v Praze

Provozně ekonomická fakulta

Precizní zemědělství a digitalizace v ČR

QK23020058



Metodika:

Správa dat v zemědělském sektoru

Michal Stočes, Jan Jarolímek (leader PS), Irena Benešová, Petr Cihelka, Lukáš Čechura, Martin Havránek, Zdeňka Žáková Kroupová, Ludmila Pánková, Jiří Vaněk

©2025 ČZU v Praze

Abstrakt:

Hlavním cílem metodiky je zajistit efektivní nakládání s daty a podpořit kvalifikované rozhodování managementu zemědělského podniku. Metodika klade důraz na vytvoření systematického přístupu k práci s daty, který zahrnuje jejich správné shromažďování, zpracování, uchování a následné využití pro analytické a strategické účely. Zdůrazňuje nutnost zabezpečit dlouhodobou dostupnost a ochranu dat před ztrátou či poškozením a zajistit jejich znovu použitelnost. Podrobně jsou popsány klíčové aspekty dat, jako jsou kvalita dat (přesnost, úplnost, konzistence) a význam metadat pro organizaci a efektivní zpracování velkého množství zemědělských dat. Metodika se zabývá riziky závislosti na dodavateli (vendor lock-in) a významem otevřených dat a jejich pětihvězdičkového hodnocení. Klíčovým prvkem je Plán správy dat (DMP), strategický dokument, který popisuje řízení dat po celou dobu jejich životního cyklu, od vzniku až po archivaci nebo výmaz. Popsány jsou role lidí ve správě dat (původce, správce, uživatel a vedení podniku). Metodika rovněž definuje datové zdroje relevantní pro zemědělství (včetně státních registrů jako LPIS, JUDPOR a JUDEH) a nastiňuje legislativní rámec, zejména ve vztahu k GDPR, Data Governance Act (DGA) a Data Act. Pro praktickou implementaci metodika představuje dva přístupy ukládání dat – pomocí souborových systémů nebo datové platformy/repozitářů a popisuje nástroje pro analytiku a podporu rozhodování (např. BI, GIS).

Klíčová slova:

Správa dat, Zemědělský podnik, Precizní zemědělství, Data Management Plan (DMP), Kvalita dat, Metadata, Otevřená data, Data Act, Systémy pro podporu rozhodování (DSS).

Obsah

1	<i>Cíl metodiky</i>	1
2	<i>Vlastní popis metodiky</i>	2
2.1	Data, informace, znalosti	2
2.1.1	Typy dat	2
2.1.2	Kvalita dat.....	3
2.1.3	Metadata a zemědělská data.....	4
2.1.4	Důvěrnost dat.....	5
2.1.5	Integrita.....	6
2.1.6	Rizika uzavřených formátů a závislosti na dodavateli	7
2.1.7	Otevřená data	7
2.2	Data v zemědělství	9
2.2.1	Potenciál využití dat v zemědělství.....	9
2.2.2	Zdroje a využití dat v zemědělství	11
2.2.3	Datové zdroje v zemědělství.....	14
2.2.4	Legislativní rámec evidence dat v zemědělství.....	15
2.3	Plán správy dat	17
2.3.1	Role lidí ve správě dat zemědělského podniku	18
2.3.2	Data Management Plan	19
2.4	Nástroje pro ukládání dat	22
2.4.1	Souborové systémy	23
2.4.2	Datové repositáře	24
2.4.3	Organizace dat	25
2.4.4	Návrh architektury datové platformy	25
2.5	Nástroje pro analytiku	26
2.5.1	Use case – práce s daty	32

3	<i>Srovnání „novosti postupů“</i>	<i>35</i>
4	<i>Popis uplatnění metodiky.....</i>	<i>36</i>
5	<i>Ekonomické aspekty.....</i>	<i>37</i>
6	<i>Seznam použité související literatury</i>	<i>38</i>
7	<i>Seznam publikací, které předcházely metodice</i>	<i>50</i>
8	<i>Jména oponentů (kteří zpracovali posudky) a názvy jejich organizací.</i>	<i>51</i>
	<i>Příloha 1: Přehled hlavních datových zdrojů pro zemědělské podniky</i>	<i>52</i>

1 Cíl metodiky

Hlavním cílem metodiky je zajistit efektivní nakládání s daty a tím podpořit kvalifikované rozhodování managementu zemědělského podniku. Metodika klade důraz na vytvoření systematického přístupu k práci s daty, který umožní jejich správné shromažďování, zpracování, uchování a následné využití pro analytické a strategické účely. Mezi dílčí cíle patří zejména zabezpečit uchování dat tak, aby byla dlouhodobě dostupná a chráněná před ztrátou či poškozením, a dále zajistit jejich znovu použitelnost, což umožní efektivní využití již získaných informací pro další analýzy a rozhodovací procesy podniku.

2 Vlastní popis metodiky

2.1 Data, informace, znalosti

Data jsou základní a neinterpretované prvky reality. Mohou mít podobu čísel, textů, záznamů senzorů, kamer, mikrofónů či jiných měřitelných hodnot. (1) Sama o sobě však nenabízejí informaci nebo porozumění – představují pouze surový materiál, který čeká na zpracování. v organizacích i ve vědě vznikají data neustále, ale jejich hodnota se projeví až tehdy, když s nimi někdo začne pracovat systematickým způsobem.

Informace a znalosti představují vyšší úroveň práce s daty. Informace vznikají uspořádáním a interpretací dat; díky tomu získávají význam a mohou být použity k analýze nebo rozhodování. Znalosti jdou ještě dál – jsou výsledkem dlouhodobého učení, zkušeností a porozumění souvislostem. Znalosti umožňují informace nejen chápat, ale také aplikovat v praxi a vytvářet z nich nové poznatky. Tento vztah se často popisuje pomocí hierarchie DIKW (*Data–Information–Knowledge–Wisdom*) (2), viz Obrázek 1.



Obrázek 1: Hierarchie Data–Information–Knowledge–Wisdom (3)

2.1.1 Typy dat

V oblasti zemědělství se využívají různé typy datových souborů, Mezi nejrozšířenější a nejpoužívanější jsou následující formát:

- **Geografická data:** Souřadnicové systémy jako GPS a GIS formáty (např. KML, Shapefile) pro mapování a analýzu půdy a plodin. (4,5)
- **Časové série:** Časová data zaznamenávající změny v čase, jako jsou klimatické podmínky nebo růst plodin. (6)
- **Kvantitativní data:** Číselná data měřící faktory jako je vlhkost půdy, pH, teplota, která mohou být ve formátech CSV nebo Excel (tabulkové formáty). (7)
- **Kvalitativní data:** Textová data popisující vlastnosti půdy nebo plodin. (8)

- **Multimediální data:** Obrazová data ze satelitů nebo dronů, často ve formátech jako JPEG, PNG pro analýzu krajiny nebo zdraví plodin. (9)

Každý typ souboru má své specifické použití a pomáhá zemědělcům v efektivním rozhodování a správě zemědělské produkce.

Pro tuto metodiku jsou definována data dle stupně zpracování takto: Primární data (pocházející přímo z měření nebo IoT senzorů), sekundární data (upravená a odvozená z primárních dat) a externí data (z meteorologických stanic, dálkového průzkumu nebo otevřených zdrojů). Základní rozdělení zdroje dat je: data z pozorování, data z měření, odvozená data, data ze simulací nebo referenční data.

V případě pořizování dat je třeba ještě brát na zřetel, zda jsou data pořizována automaticky nebo manuálně.

2.1.2 Kvalita dat

Kvalita dat obecně vyjadřuje, nakolik jsou data vhodná k použití pro konkrétní účel. (10) Posuzuje se podle několika dimenzí, jako je přesnost (odpovídají realitě), úplnost (nechybí důležité informace), konzistence (neodporují si napříč systémy), aktuálnost (jsou dostatečně čerstvá), validita (splňují požadovaný formát a pravidla) a jedinečnost (neobsahují duplicity). (11) Kvalita dat ve vztahu k požití dat (data ingestion) znamená, do jaké míry jsou přijímaná data přesná, úplná, konzistentní, aktuální a použitelná pro svůj účel. Při ingestu je cílem zajistit, aby data splňovala stanovené požadavky – provádí se validace formátů, čištění chyb, deduplikace, standardizace a detekce anomálií, protože čím dříve se problémy zachytí, tím menší dopad mají na další zpracování. (12,13) Klíčovou roli v tomto procesu hrají metadata, tedy „data o datech“, která popisují strukturu, význam, formát a původ dat. (14) Metadata obsahují pravidla kvality, schémata, definice sloupců, požadavky na validaci i informace o původu a aktuálnosti dat. Díky nim je možné automaticky kontrolovat kvalitu při ingestu, správně data interpretovat a udržovat jejich konzistenci napříč systémy. (15) Bez metadat je řízení kvality nespolehlivé a obtížně automatizovatelné, zatímco s metadaty lze zajistit, že příchozí data jsou správná, dobře pochopitelná a použitelná pro další analytické či provozní účely.

2.1.3 Metadata a zemědělská data

Metadata jsou definována jako strukturovaná data, která poskytují informace o jiných datech.

(14) Tato metadata mohou v oblasti zemědělství zahrnovat informace jako jsou geografická umístění, časové razítko sběru dat, typy použitých senzorů, meteorologické podmínky, a specifika půdy nebo plodin. (16) Využívají se k organizaci, vyhledávání a efektivnímu zpracování velkého množství zemědělských dat, což zvyšuje efektivitu a přesnost rozhodovacích procesů v rámci precizního zemědělství. (16) Důležitou součástí je také jejich role v zajišťování interoperability mezi různými datovými systémy a platformami. (17)

Role metadat

Metadata hrají klíčovou roli v klasifikaci dat, protože poskytují:

- **Popis dat:** Zahrnují informace o původu, autorovi, datu vytvoření a kvalitě dat.
- **Organizaci dat:** Pomáhají při třídění a filtrování dat podle definovaných kritérií.
- **Automatizaci:** Umožňují snadnější přístup a integraci dat prostřednictvím API rozhraní nebo datových katalogů.

Metadata mohou být uložena v různých formátech, například JSON, XML, CSV, YAML, RDF apod., podle toho, jaký systém či aplikace je zpracovává. Výhodou těchto formátů (JSON, XML, CSV, YAML, RDF) je, že umožňují strojové i lidské čtení a snadnou výměnu dat mezi různými systémy.

Příklad metadat ve formátu JSON:

```
{
  "identifikace": {
    "nazev": "Monitoring růstu pšenice ozimé 2025",
    "popis": "Datová sada obsahuje informace o vývoji porostů pšenice ozimé na pokusných parcelách v období 2024-2025.",
    "klicova_slova": ["zemědělství", "pšenice", "půda", "výnos", "satelitní snímky"],
    "jazyk": "cs",
    "datum_vytvoreni": "2025-03-15",
    "autor": "Česká zemědělská univerzita v Praze - Katedra informačních technologií",
    "kontakt": "stoces@pef.czu.cz",
    "verze": "1.0"
  },
  "prostorova_informace": {
    "lokalita": "Praha Suchdol, Česká republika",
    "souřadnice": {
      "souřadnicový_systém": "WGS84",
      "min_lat": 48.94,
      "max_lat": 49.05,
      "min_lon": 14.40,
      "max_lon": 14.55
    },
    "rozliseni": "10 m/pixel",
    "zdroj_danych": ["Sentinel-2", "pozemní měření"]
  },
  "casove_informace": {
```



```

    "obdobi_zaznamu": {
      "od": "2024-10-01",
      "do": "2025-07-31"
    },
    "frekvence_sberu": "týdně"
  },
  "tematicka_informace": {
    "typ_danych": "rastr, tabulka",
    "jednotky": ["NDVI", "kg/ha", "°C"],
    "atributy": [
      {"nazev": "NDVI", "popis": "Index vegetačního pokryvu"},
      {"nazev": "vyska_porostu", "popis": "Výška rostlin v cm"},
      {"nazev": "vlhkost_pudy", "popis": "Obsah vody v půdě v %"},
      {"nazev": "teplota_vzduchu", "popis": "Průměrná teplota vzduchu v °C"}
    ]
  },
  "podminky_pristupu": {
    "licence": "CC BY 4.0",
    "dostupnost": "volně dostupné",
    "url": "https://data.czu.cz/metadata/pšenice2025"
  }
}

```

Tento příklad metadat přehledně popisuje klíčové prvky datové sady. Sekce identifikace poskytuje základní informace potřebné pro jednoznačné určení datasetu a jeho autora. Prostorová informace doplňuje údaje o geografickém umístění a zdrojích dat, což je zásadní pro zemědělské a environmentální aplikace. Časová informace udává období a frekvenci měření, čímž umožňuje pochopit časový kontext dat. Tematická informace charakterizuje obsah a strukturu dat, tedy jaké veličiny a jednotky jsou měřeny. Nakonec podmínky přístupu určují licenční ujednání a dostupnost, což je důležité pro správné sdílení a opětovné využití datasetu.

2.1.4 Důvěrnost dat

Je definovaná jako zajištění přístupu k datům pouze oprávněným osobám. Přístup k datům oprávněných osob řeší každá organizace, a to minimálně na úrovni pravomocí a odpovědností vyplývajících z pracovního zařazení konkrétního pracovníka a z jeho pracovní náplně. (18) Každé zveřejnění nebo prozrazení informace, která nemá být zveřejněna nebo není určena konkrétnímu pracovníkovi lze považovat jako porušení důvěrnosti. z hlediska důvěrnosti se data dělí do skupin: veřejná data, interní data, důvěrná data; přísně důvěrná data. (19)

Veřejná data

Jedná se o data, která jsou veřejně přístupná, bez nutnosti ověření identity uživatele.

Interní data

Interní data jsou převážně určena interním uživatelům, kteří jsou ověřeni, ale u těchto dat není nutné rozlišení přístupových oprávnění. v případě zcizení těchto dat není pravděpodobné narušení důvěrnosti dat.

Důvěrná data

Data označená jako důvěrná jsou určena pouze uživatelům, kteří je potřebují pro jejich práci. Pro přístup k nim je nutné nastavení příslušného oprávnění konkrétnímu uživateli/skupině uživatelů. u těchto dat je zvýšené riziko zneužití při zcizení.

Přísně důvěrná data

Kategorie přísně důvěrných dat je určena pro velmi omezený počet výslovně vyjmenovaných uživatelů. u těchto dat je vhodné logování přístupu k těmto datům, včetně automatizovaného vyhodnocení těchto přístupů.

2.1.5 Integrita

Integrita je zajištění správnosti a úplnosti informací. Pomocí určitých matematických operací je možné určit, jestli nedošlo při přenosu určitého souboru k jeho pozměnění. Pokud soubor nebyl pozměněn a jeho příjemce ho obdrží právě takový, jaký byl odeslán, budeme hovořit o dodržení integrity souboru. z hlediska integrity lze dělit informace na doplňkové informace, interní informace, důležité informace, autentické informace. (20) Integrita dat znamená, že informace zůstává úplná, nepozměněná a pravdivá, a to jak při ukládání, tak při přenosu či zpracování. v rámci ochrany utajovaných informací, jak je vymezuje NBÚ do stupňů *Vyhrazené, Důvěrné, Tajné a Přísně tajné*, hraje integrita klíčovou roli, protože neoprávněná změna dat může mít stejně závažné následky jako jejich prozrazení. u informací stupně *Vyhrazené* může narušení integrity vést k omezené či lokální újmě na činnosti státu nebo organizace. u stupně *Důvěrné* by změna dat mohla výrazně ovlivnit bezpečnostní nebo správní procesy. u informací *Tajných* už jejich pozměnění může vážně ohrozit obranu, bezpečnost nebo mezinárodní závazky ČR. a u stupně *Přísně tajné* by ztráta integrity mohla mít kritické až katastrofické dopady, protože jde o materiály zásadní pro bezpečnost státu. Zajištění integrity je tedy povinnou součástí ochrany utajovaných informací napříč všemi stupni a určuje se podle potenciální míry újmy, kterou by pozměnění informace mohlo způsobit.

2.1.6 Rizika uzavřených formátů a závislosti na dodavateli

Uzavřené, tzv. proprietární datové formáty představují pro podnik dlouhodobé riziko, protože omezují svobodnou práci s vlastními daty. Když jsou informace uloženy v podobě, kterou dokáže otevřít jen jeden konkrétní software nebo služba, podnik se dostává do situace, kdy bez tohoto dodavatele nedokáže se svými daty efektivně pracovat. (21) Může to fungovat krátkodobě, ale problém nastává ve chvíli, kdy dodavatel změní obchodní podmínky, přestane software podporovat, zvýší cenu nebo dokonce ukončí činnost. (22) v takové chvíli může být velmi obtížné, nebo nákladné, převést data jinam – někdy to dokonce není možné vůbec. Stejný problém nastává i tehdy, když systém neumožňuje snadný export dat nebo je ukládá tak, že jsou plně „uzamčena“ uvnitř jednoho řešení. (23) Tento stav se označuje jako *vendor lock-in*, tedy závislost na dodavateli, která výrazně snižuje flexibilitu organizace a omezuje její možnosti do budoucna. (24)

Zásadní otázkou je také to, kdo je skutečným vlastníkem dat. v běžné praxi platí, že vlastníkem dat je vždy podnik, který je vytváří nebo shromažďuje, nikoli poskytovatel softwaru. Přesto je nezbytné, aby to bylo jednoznačně stanovené ve smlouvě, a aby měl podnik jasně definovaná práva k používání, exportu i mazání dat. Někteří dodavatelé si totiž mohou ve smluvních podmínkách vyhradit práva k analyzování, sdílení či jinému využívání dat zákazníka, a podnik si toho nemusí být vědom. Proto je důležité mít možnost kdykoli data vyexportovat do otevřených a široce podporovaných formátů a mít jistotu, že organizace má nad svými informacemi plnou kontrolu. Tím se výrazně snižuje riziko, že se podnik dostane do slepé uličky, kdy se s vlastním datovým obsahem nedokáže svobodně a nezávisle pracovat. (25)

2.1.7 Otevřená data

Otevřená data (*angl. open data*) jsou zvláštní kategorií dat, která jsou zpřístupněna veřejnosti pod otevřenou licenci a ve strojově čitelných formátech. (26) Umožňují komukoli tato data volně používat, analyzovat, kombinovat a vytvářet z nich nové služby či výzkumné výstupy. (27) Otevřená data podporují transparentnost státní správy, inovace v podnikání a vývoj aplikací založených na faktech (27–29). Pro vzdělanou veřejnost představují důležitý zdroj pro informované rozhodování a tvorbu nových poznatků. (30) Systém hodnocení pro otevřená data, navržený Timothim Bernersem-Leem, lze vidět na Obrázku 2:



Obrázek 2: Pětihvězdičkové hodnocení pro otevřená data. (31)

Stupeň 1 – data dostupná online pod otevřenou licencí

V tomto stupni je datová sada zveřejněna na webu a je volně přístupná pod otevřenou licencí. u prostorových dat sem patří například služby OGC WMS a OGC WMTS. Tyto služby ale neposkytují samotná data, pouze obrázky vytvořené z dat. Obrázky nejsou strojově čitelné, a proto je tento stupeň považován za nejnižší formu otevřenosti. (31)

Stupeň 2 – data ve strojově čitelném formátu

Ve druhém stupni jsou data poskytována ve formátu, který lze automatizovaně zpracovat. Programy z něj dokážou získat jednotlivé prvky i jejich strukturu. Tento stupeň však nevyžaduje použití otevřených formátů. Mohou se používat i proprietární nebo komerční soubory, což omezuje jejich využití. Proto není stupeň 2 považován za dostatečně otevřený. (31)

Stupeň 3 – data v otevřeném neproprietárním formátu

Třetí stupeň vyžaduje, aby byla data dostupná ve formátu s volně dostupnou specifikací. Pro prostorová data jsou vhodné otevřené formáty OGC, například GML, KML nebo GeoPackage. Za otevřený lze považovat i formát ESRI Shapefile nebo GeoJSON, protože mají širokou podporu a nejsou licenčně omezené. Nehodí se však na všechny typy dat. (31)

Stupeň 4 – data podle standardů W3C

Ve čtvrtém stupni se data ukládají, přenášejí i dotazují pomocí standardů W3C, tedy URI, HTTP, RDF a SPARQL. Díky tomu lze data snadno propojovat a pracovat s nimi na webu jako se součástí širšího datového ekosystému. (31)

Stupeň 5 – propojená data

Nejvyšší stupeň otevřenosti znamená, že data jsou propojena s dalšími datovými sadami. Využívají strojově čitelné odkazy podobné hypertextovým odkazům, které umožňují vyjadřovat vztahy mezi různými daty. Taková data tvoří základ pro koncept *Linked Open Data*. (31)

2.2 Data v zemědělství

2.2.1 Potenciál využití dat v zemědělství

Rozvoj digitálních technologií a nástup éry velkých dat zásadním způsobem proměnily způsoby, jakými lze v zemědělství data shromažďovat, vyhodnocovat a využívat. Zemědělství je dnes významným producentem dat, a to jak v důsledku technologického pokroku (senzorika, IoT, dálkový průzkum Země), tak i z důvodu legislativních povinností souvisejících s bezpečností potravin, ochranou zdraví a zásadou „od farmáře ke spotřebiteli“. (32) Přestože objem dat produkovaných zemědělskými subjekty neustále roste, jejich využitelnost pro pokročilé analytické účely je v mnoha případech omezená. Tento rozpor mezi potenciálem a realitou představuje jeden z hlavních limitů současné digitalizace sektoru.

Zemědělská data bývají nedostatečně konzistentní, neúplná nebo zatížená chybami, které vyplývají především z manuálního zadávání, absence metadat či nejednotných procesů sběru. Provozní podmínky zemědělských podniků se vyznačují vysokou variabilitou – jak prostorovou, tak časovou – což zvyšuje nároky na standardizaci měření a validaci dat. v praxi to vede k nejednotné kvalitě záznamů i mezi podniky podobného typu. Tyto nedostatky následně komplikují využití dat pro statistické a ekonomické modelování, predikce počasí a výnosů, hodnocení účinnosti zásahů nebo trénink modelů umělé inteligence. (33)

Rozdílná interpretace datových ukazatelů mezi jednotlivými uživateli rovněž vede k informačním nesouladům. Návrh efektivních procesů řízení dat proto vyžaduje nejen technické standardy, ale i jasně definovanou terminologii, postupy a institucionální odpovědnosti, které minimalizují riziko chyb vznikajících při interpretaci nebo manuálním přenosu dat.



Kvalita dat není pouze technickým problémem; zásadní roli zde hraje i lidský faktor a sociální interakce mezi aktéry, kteří data vytvářejí, zpracovávají a využívají. Zemědělci, technici, poradci, výzkumníci, státní instituce a dodavatelé systémů pracují s odlišnými cíli a omezeními. Zemědělci obvykle upřednostňují aktuální operativní rozhodnutí, zatímco výzkumné a analytické týmy potřebují dlouhodobé konsistentní řady dat, které umožní identifikovat trendy a vztahy. Dotazníková šetření, která jsou často zdrojem ekonomických a sociálních dat, bývají zatížena tzv. „*recall bias*“, tedy nepřesnými retrospektivními odpověďmi respondentů. (34) Tato zkreslení významně ovlivňují kvalitu výzkumu a následné modely rozhodování. (35) Proto je nezbytné systematicky zavádět postupy, které omezí vliv neúplných, opožděných nebo nepřesně reportovaných dat – například automatizací sběru, standardizací záznamu nebo zavedením auditních mechanismů.

Technologický vývoj přináší stále rozsáhlejší možnosti plně nebo částečně automatizovaného sběru dat. Senzory, IoT zařízení, GPS jednotky, meteorologické stanice, drony a systémy dálkového průzkumu Země umožňují generovat velké množství objektivních dat, a to často v téměř reálném čase. Tyto technologie otevírají cestu k přesnějším produkčním modelům, prediktivní analýze a optimalizaci vstupů, což vede k efektivnějšímu hospodaření i k vyšší udržitelnosti produkce. Automatizace sběru dat navíc omezuje chybovost spojenou s lidským zadáváním a umožňuje systematické ukládání dat v definovaných standardizovaných formátech. Vazba na inteligentní rozhodovací systémy (IDSS) zvyšuje požadavky na kvalitu dat, neboť rozhodovací modely vstupní data nejen využívají, ale mohou na základě jejich charakteru měnit strategie řízení podniku. (36) Data se tak stávají aktivem, které má přímý vliv na efektivitu a ekonomické výsledky.

Modely strojového učení a umělé inteligence vykazují v zemědělství slibné výsledky, avšak jejich úspěšnost je výrazně ovlivněna kvalitou vstupních dat. Nedostatečná anotace, nekompletní záznamy, heterogenní formáty či odlišné postupy sběru mezi jednotlivými podniky způsobují, že modely často neumějí generalizovat, jsou obtížně validovatelné a jejich doporučení nejsou dostatečně robustní pro reálný provoz. (37)

2.2.2 Zdroje a využití dat v zemědělství

Pro pochopení dostupnosti a podoby dat v zemědělství je nutné vnímat zemědělská data jako komplexní problematiku se všemi jejími faktory, specifiky a vazbami. Není možné se zaměřit pouze na jednu konkrétní oblast. Pro orientaci ve zdrojích a využití zemědělských dat slouží Mapa dat v zemědělství (viz Obrázek 3). Vymezuje hlavní skupiny producentů a uživatelů zemědělských dat. Na mapě jsou zobrazeny úrovně, do kterých můžeme definovat zdroj dat: oblasti zemědělské výroby, komodity, měřené veličiny, technologie používané pro sběr dat až po konkrétní zařízení/senzor. Barevná škála představuje míru využití daného datového zdroje, tmavá odpovídá nejvyšší míře využití, oranžová je spíše cílem nebo jen vizí. Uvedená škála vychází z dosavadních poznatků.



Obrázek 3: Mapa dat v zemědělství (38)

Charakteristika hlavních zdrojů a uživatelů zemědělských dat

- **Farmářská data**

Klíčovými producenty, ale také uživateli dat jsou, nebo by alespoň měli být zemědělci nebo zemědělské podniky. (39) v podstatě všechny technologie, procesy, a výzkumy by měly sloužit k efektivní zemědělské výrobě.

V zemědělských podnicích se generuje velké množství dat; jejich specifikace a úplný seznam je záležitostí samostatné studie. Tato studie se zabývá způsobem jejich využití. Data získaná a použitá v jedné společnosti lze označit jako primární. Převažující metodou je jednorázové použití v místě vzniku, kdy získaná data slouží k řešení aktuální situace a často se ani neukládají, tato metoda se dá nazvat "*použij a vyhod*". Část těchto dat se také používá pro různé interní záznamy. Pouze malá část získaných dat je pak využívána opakovaně. Cílem by však měla být kompletní archivace a možnost sdílení – pro další chytré využití těchto dat v daném podniku, ale i dalšími zainteresovanými subjekty – především ve výzkumu, ale i dalšími zainteresovanými stranami, samozřejmě s ohledem na zásady ochrany a anonymizace osobních údajů.

V současné době je archivace dat z farem v potřebné kvalitě pro další využití spíše vizí. Data získaná od zemědělských podniků jsou již ve většině případů druhotnými údaji, zpracovanými a upravenými za účelem použití. Stát získává data z povinného reportingu pro své potřeby. (40) Výzkumné organizace pak získávají potřebná data ze státních výkazů a záznamů a různých výběrových šetření při řešení konkrétních projektů. (41) Často je snazší získat potřebná data pro výzkum experimentálně než s využitím stávajících údajů o farmách. i to může být jednou z příčin problému praktického uplatnění výsledků vědy a výzkumu.

- **Dodavatelská data**

Součástí dodávek technologií, pesticidů, hnojiv, krmných směsí a všech dalších surovin a služeb jsou i data a informace definující parametry a způsob použití těchto surovin. Poskytování některých informací je diktováno legislativou, např. etiketami pesticidů. (42) Velká část informací pak slouží pro rozhodnutí o využití dané technologie/suroviny a samotném využití. Velká část těchto informací slouží a je prezentována dodavateli pro podporu prodeje a související poradenství pro použití v zemědělských podnicích. Využití

těchto dat jinými subjekty je primárně z volně dostupných zdrojů, nebo na základě konkrétní spolupráce, např. využití ve výzkumu.

- **Tržní data**

Charakterizují trh se zemědělskými zdroji a komoditami. Data z komoditních burz, elektronických trhů apod. lze klasifikovat jako primární. Velká část dat pak pochází ze statistických šetření států, Evropské unie (43,44) a různých oborových asociací na národní i mezinárodní úrovni. (45) Ve většině případů je dostupnost dat pro všechny potřebné subjekty rovnocenná. (44)

- **Státní data**

Všechny státy prezentují značné množství dat a informací pro řízení sektoru v oblasti zemědělství, jedná se o legislativu, různé normy a pravidla. (45–47) Dalšími oblastmi jsou výstupy kontrolních mechanismů, státem organizovaných statistických zjišťování apod. u dat prezentovaných státem se bavíme o principu tzv. *Otevřená data* (Kapitola 2.1.7), tedy volně šiřitelných dat s možností strojové čitelnosti.

- **Data z vědy a výzkumu**

Jedná se o výstupy výzkumných organizací, dostupnost pro zemědělce a další subjekty je především ve formě inovací, často jsou součástí vzdělávacích programů vysokých škol, kde dochází k propojení výzkumu a vzdělávání. Transfer výsledků výzkumu a vývoje do praxe je však samostatnou, ne vždy příliš úspěšnou kapitolou výzkumu.

Při sdílení těchto dat ve výzkumné sféře mezi různými výzkumnými pracovišti hovoříme o tzv. *FAIR* datech, resp. *FAIR* principech. (48–53)

- **Externí data**

V Datové mapě v zemědělství je tato část využita pro zahrnutí dat, která nelze zařadit do předchozích skupin, přestože je jejich význam značný. Jedná se například o data z oborů, jako je meteorologie, dálkový průzkum Země a další. (51,54,55) Velká část těchto údajů je k dispozici na základě principů *otevřených dat 2.1.7* (41,56–58), ale někdy jsou také získávána z obchodních vztahů. (59) Ve většině případů je však dostupnost dat ekvivalentní pro všechny potřebné subjekty.

2.2.3 Datové zdroje v zemědělství

Hlavními zdroji dat pro zemědělský podnik jsou interní podniková data a externí informace od dodavatelů, veřejné správy, trhu a výzkumu. (38) v podmínkách ČR existuje řada klíčových resortních systémů a registrů, které slouží pro evidenci půdy, vstupů i hospodářských zvířat. Tyto systémy jsou využívány jak pro plnění legislativních povinností, tak pro podporu rozhodování v rostlinné i živočišné výrobě. Například *LPIS (Land Parcel Identification System)* představuje ústřední registr půdy a jejího využití – eviduje zemědělské půdní bloky a hraje nezastupitelnou roli v moderním zemědělství a při správě dotací. (60) Doplněním LPIS jsou *bonitované půdně-ekologické jednotky (BPEJ)*, což je klasifikace kvality půdy pomocí pětimístných kódů, popisujících agroekologické charakteristiky pozemků (klíma, půdní typ, sklon apod.). (61) BPEJ slouží jako podklad pro hodnocení produkční schopnosti půdy a agronomická rozhodnutí.

Pro oblast živočišné výroby je zásadní ústřední evidence hospodářských zvířat (zejména skotu), vedená *Českomoravskou společností chovatelů (ČMSCH)* dle plemenářského zákona. Tento registr zaznamenává veškeré události jako narození, úhyny či přesuny zvířat a je provozován elektronicky – chovatelé hlásí údaje prostřednictvím online systému (*Portál farmáře*) nebo aplikací ČMSCH. (62) Evidence zvířat je nezbytná pro sledování zdravotního stavu stád, šlechtění i plnění legislativních požadavků (např. označování zvířat a sledovatelnost původu).

V posledních letech byly zavedeny také centrální systémy pro elektronickou evidenci vstupů v rostlinné výrobě. *JUDPOR (Jednotné úložiště dat evidence přípravků na ochranu rostlin)* slouží k ohlašování použití pesticidů na zemědělské půdě. (63) Podobně *JUDEH (Jednotné úložiště dat evidence hnojení)* je určeno pro záznamy o aplikaci průmyslových i statkových hnojiv. (64) Oba tyto systémy jsou napojeny na *Portál farmáře Ministerstva zemědělství* a data se do nich předávají elektronicky v předepsaném formátu. Povinné vedení evidence hnojení a použití *POR (přípravků na ochranu rostlin)* se týká zatím větších podniků (nad 200 ha) a postupně se rozšiřuje v rámci snahy o lepší dohled nad ochranou půdy a vodasz.cz. Portál farmáře obecně funguje jako jednotné rozhraní pro přístup k těmto registrům a agendám (LPIS, registr zvířat, dotace, evidence vstupů aj.).

Dalším zdrojem dat jsou oficiální statistiky – *Český statistický úřad* publikuje pravidelné přehledy o stavech hospodářských zvířat, produkci masa, mléka a dalších ukazatelích

živočišné výroby. (65) Tyto agregované údaje umožňují podnikům srovnat vlastní výsledky s průměrem odvětví a sledovat trendy. Ve výzkumné sféře pak vznikají otevřené datové sady (např. meteorologická data, dálkový průzkum Země), které mohou zemědělské podniky využít pro precizní řízení.

Pro efektivní využití potenciálu výše zmíněných zdrojů je nutná jejich integrace a správná interpretace. Velké objemy dat z různých systémů nelze efektivně zpracovávat ručně; prosazuje se využití nástrojů *Business Intelligence* (BI) a *systémů pro podporu rozhodování* (DSS), které dokážou data z podnikových i externích zdrojů analyzovat v reálném čase. (38) k zajištění důvěryhodnosti výstupů je klíčová kvalita dat a standardizace formátů i metadata – jednotné popisy dat usnadňují jejich sdílení a opakované využití. (66) v praxi se proto doporučuje vypracovat *Data Management Plan* (DMP) podniku, který stanoví pravidla pro sběr, ukládání, zálohování a sdílení dat. pse.agriculturejournals.cz. Dodržování těchto principů (viz např. FAIR data v metodice dle Stočes et al. (67)) zaručí, že data zůstanou dlouhodobě využitelná pro potřeby podniku i případný transfer znalostí do poradenské či vědecké sféry.

Tabulka shrnující vybrané datové zdroje relevantní pro zemědělské podniky, včetně jejich charakteristik a významu pro živočišnou výrobu viz Příloha 1.

2.2.4 Legislativní rámec evidence dat v zemědělství

Metodika řízení dat v precizním zemědělství musí propojit dvě roviny: (i) povinné e-evidence a regulatorní výstupy (hnojiva, pesticidy, živočišná výroba, účetnictví) a (ii) správu, sdílení a další využití dat (výzkum, analýzy, učení modelů). Bez jasného vymezení práv (farmář vs. správce databáze) a bez návaznosti na *GDPR*, *Data Governance Act* a *Data Act* hrozí, že data budou zpracovávána v rozporu s účelem, že nebude respektována práva „původce dat“, nebo že instituce nesplní zákonné reportingové povinnosti. Metodika proto stanoví klasifikaci dat a procesy pro jejich sběr, sdílení, přenos, výmaz a dlouhodobou archivaci v návaznosti na konkrétní povinnosti v ČR a EU.

U hospodařících nad 200 ha zůstává povinnost vést evidenci hnojení elektronicky a na výzvu ji předat ÚKZÚZ (*Ústřední kontrolní a zkušební ústav zemědělský*) přes *Portál farmáře* do JUDEH; plošné „automatické“ odesílání dat má být zrušeno a nahrazeno předáváním pro kontrolní účely (*novela s účinností od 15. 07. 2025*). (68) Archivace evidencí se řídí zvláštními předpisy a podmínkami kontroly.

U *přípravků na ochranu rostlin* (POR) musí profesionální uživatelé bez zbytečného odkladu zaznamenat každé použití, do 30 dnů převést záznam do elektronické podoby a poskytovat jej v předepsaném formátu; pro subjekty nad 200 ha je zavedeno elektronické předávání do JUDPOR (*Portál farmáře*). (69)

Identifikace a ústřední evidence hospodářských zvířat (registrace chovatele, hlášení narození, úhynů, přesunů) probíhá elektronicky dle plemenářského zákona (70); provoz a metodiku zajišťuje ČMSCH. (62)

Účetní doklady se obvykle uchovávají minimálně 5 let, účetní závěrka 10 let; digitální forma je přípustná, pokud je zachována věrohodnost, čitelnost a integrita. (71) Nařízení pro financování SZP vyžadují IACS/LPIS a propojené registry jako základ pro kontrolu podmíněnosti a dotací; národní implementace v ČR probíhá přes *Portál farmáře* a resortní registry. (72,73)

Pokud databáze obsahují osobní údaje (např. kontakty farmářů/zaměstnanců, geolokace spojené s fyzickou osobou), správce musí plnit zásady čl. 5 (zákonnost, účelové omezení, minimalizace, přesnost, integrita a důvěrnost) a čl. 32 (bezpečnost) *Obecného nařízení o ochraně osobních údajů* (GDPR). Veřejné instituce typicky jmenují pověřence pro ochranu osobních údajů (DPO) a u rizikových projektů provádějí DPIA. Sekundární využití (např. učení modelů) vyžaduje kompatibilitu účelu, anebo nový právní titul; u souhlasu je klíčové právo na odvolání a případně výmaz. (74)

Nařízení 2022/868 (DGA) upravuje zprostředkovatele dat a datový altruismus; posiluje důvěru ve sdílení neosobních i osobních dat za přísných pravidel nestrannosti a bezpečnosti. Provozovatelé sektorových platforem (vč. univerzit) musí vyhodnotit, zda do režimu DGA nespádají. (75)

Nařízení 2023/2854 (*Data Act*) zavádí právo uživatele připojeného produktu/služby na data, která zařízení generují (v zemědělství typicky strojová/senzorová data), a principy spravedlivého přístupu (FRAND). Zároveň stanoví omezení pro sekundární využití poskytovaných dat (např. zákaz použít přístupová data k vývoji konkurenčního produktu; zvláštní pravidla vůči „gatekeeperům“). Od 12. 9. 2025 je *Data Act* plně použitelný. To se promítá do smluvních a technických kontrol při trénování modelů nad daty farmářů. (76)

Povinnost zveřejňovat *open-data* se vztahuje primárně na povinné subjekty dle zákona č. 106/1999 Sb. a na subjekty veřejného sektoru dle *Open Data Directive*; soukromé agrární registry obecnou povinnost veřejného zpřístupnění nemají, ledaže to stanoví zákon či smlouva. (71)

V kontinentálním právu neexistuje vlastnické právo k datům jako k věci. Ochrana se odvíjí od GDPR, obchodního tajemství, autorskoprávní ochrany databáze (*sui generis*) a hlavně od smluv. *Sui generis* právo chrání investici do shromažďování/ověřování/prezentace obsahu, nikoli samotné „vytvoření“ dat; judikatura SDEU (C-203/02 *BHB v. William Hill* aj.) potvrdila, že „*spin-off*“ databáze z vlastní činnosti nemusí požívat ochranu bez významné investice do sběru/ověřování. (77)

V zemědělství se v praxi prosadil EU *Code of Conduct on Agricultural Data Sharing*, který vymezuje původce dat (*data originator*) – zpravidla farmáře – a doporučuje, aby měl kontrolu nad přístupem a využitím dat, včetně smluvního „*opt-out*“ a výmazu/vrácení dat při ukončení služby. Kodex je nezávazný, ale stal se odvětvovou referencí pro smluvní ujednání (přístupová práva, audit, přenositelnost). (78)

Tato *soft-law* pravidla posiluje ve vztahu k datům z IoT zařízení *Data Act*: uživatel (farma) má právně vymahatelné právo přístupu a sdílení dat s třetí osobou a správci musí technicky umožnit export a omezit vlastní sekundární využití v rozporu s nařízením (včetně omezení vůči „*gatekeeperům*“). Pro osobní údaje zároveň platí veškerá práva podle GDPR (odvolání souhlasu, výmaz), tj. „stažení“ osobních dat z učení modelu je povinnost posuzovat podle právního titulu a technické proveditelnosti. (79)

2.3 Plán správy dat

Pro správu dat je nutné vytvářet, udržovat a aktualizovat plány správy dat. Vytvoření plánu správy dat (DMP) v organizaci zahrnuje systematický přístup, který zajistí, že data budou spravována efektivně, bezpečně a v souladu s příslušnými předpisy. (80–82)

Východiskem pro řešení dostupnosti dat v zemědělském podniku je uvědomění si současné situace ve využívání dat a promarněného potenciálu způsobeného špatnými postupy uchovávání dat. (82)

2.3.1 Role lidí ve správě dat zemědělského podniku

Správa dat není jen technickou disciplínou. v zemědělských podnicích, kde jsou personální kapacity omezené a mnoho zaměstnanců zastává více funkcí zároveň, je klíčovým faktorem právě člověk. (83) Podniky často čelí nedostatku kvalifikovaných lidí, vysokému pracovnímu zatížení a nízkému stupni digitalizace. Postupy správy dat proto musí být jednoduché, přehledné a snadno proveditelné. Je vhodné minimalizovat ruční zadávání, zavádět automatizaci, kde je to možné, a poskytovat průběžné školení. (84) Správa dat je dlouhodobý proces a úspěšná může být pouze tehdy, pokud zaměstnanci rozumějí jejím přínosům a mají pro ni vytvořené podmínky.

Kvalita dat závisí především na tom, jak lidé pracují, jak jsou proškoleni a jaké mají podmínky. (84,85) Metodika proto reflektuje skutečnost, že ve většině podniků neexistují specializované datové pozice a většinu úkolů zajišťuje úzký tým nebo jediný pracovník. (86) Je třeba vnímat následující role pracovníků ve vztahu k práci s daty.

Původce dat

Zaměstnanci, kteří data vytvářejí – obsluha strojů, agronomové, zootechnici i administrativní pracovníci – jsou základem celého procesu. (87–91) Jejich úkolem je zapisovat údaje pravdivě, úplně a podle stanovených pravidel. Sběr dat probíhá v provozních podmínkách a často v časové tísní, proto je důležité používat jednoduché formuláře, jednotné názvy a jasně popsané postupy. Chyby či technické problémy je nutné neprodleně hlásit.

Správce dat

Většina zemědělských podniků nemá kapacity pro specializované technické role. Tuto funkci proto zpravidla zastává jeden pracovník — například agronom, ekonom nebo technik — který vedle svých hlavních povinností zajišťuje i organizaci a základní správu dat. (87–91) Jeho úkolem je udržovat pořádek ve struktuře souborů, kontrolovat úplnost evidencí a řešit základní administraci systémů (přístupy, zálohy, komunikace s dodavateli). Tato role je spíše organizační; cílem není provoz složité IT infrastruktury, ale udržení základních standardů potřebných pro kvalitu dat.

Uživatel dat

Do této skupiny patří pracovníci, kteří s daty přímo pracují při plánování a rozhodování – management, ekonomické oddělení, agronomové nebo poradci. (87–91) Pro správnou interpretaci je nutné rozumět tomu, odkud data pocházejí, jak jsou strukturována a jaká mají omezení. Uživatelé dat zároveň poskytují zpětnou vazbu k úpravě postupů a zlepšení datové kvality.

Vedení podniku

Vedení plní roli vlastníka dat. Stanovuje pravidla, přiděluje odpovědnosti, rozhoduje o sdílení dat a schvaluje *Data Management Plan*. (87–91) Zajišťuje také podmínky pro to, aby byly datové procesy dlouhodobě udržitelné. Bez aktivní podpory vedení není možné nastavit a udržet systematický přístup ke správě dat.

2.3.2 Data Management Plan

Data Management Plan (DMP) je strategický dokument, který popisuje, jak budou data v podniku spravována po celou dobu jejich životního cyklu – od vzniku, přes zpracování a ukládání až po archivaci či výmaz. Slouží jako nástroj pro systematické, bezpečné a dlouhodobě udržitelné nakládání s daty. DMP zajišťuje, že informace budou dostupné, kvalitní a využitelné pro provozní, kontrolní i analytické účely. (80)

Plán správy dat má odpovídat místním podmínkám zemědělského podniku – jeho velikosti, technickému vybavení, personálním možnostem a používaným technologiím. v dobře fungující podobě přináší přehled, snižuje chybovost a umožňuje sdílení dat bez rizik a nejasností. (82,92)

1. krok – Identifikace

Prvním krokem je identifikace způsobu, jakým data v podniku vznikají a jak se s nimi pracuje. (87,92,93) Cílem je pojmenovat problémy a potřeby. Pomáhají k tomu otázky, které odhalují klíčové nedostatky:

- Máme zařízení, která produkují data?
- Ukládáme získaná data?
- Jsme schopni uložená data znovu použít?

- Je možné sdílet uložená data mezi různými aplikacemi, technologiemi a informačními systémy v rámci společnosti?
- Je možné sdílet uložená data s jinými subjekty (dodavateli, spotřebiteli, státem, výzkumnými týmy atd.)?
- Máme data pokrývající všechny potřebné oblasti výroby?

2. **krok – Evidence**

Evidence je druhým klíčovým krokem v procesu správy dat a představuje systematické zmapování toho, jaká data podnik skutečně má, odkud pocházejí, v jaké kvalitě se nacházejí a kdo za ně odpovídá. (87,92,93) Zatímco krok *Identifikace* slouží k odhalení problémů a potřeb, krok Evidence poskytuje konkrétní a strukturovaný přehled datových sad, který se následně stává základem pro tvorbu samotného *Data Management Planu*.

Cílem evidence je vytvořit ucelený „inventář dat“ – tedy jasně popsany seznam všech datových zdrojů, datových sad, způsobů jejich sběru a aktuálního stavu. Tato fáze je zásadní, protože umožňuje objektivně vyhodnotit, co je v podniku dostupné, co je nutné doplnit nebo standardizovat a jaká data mají prioritu pro další práci.

Evidence by měla obsahovat seznam datových zdrojů, typy uchovávaných dat, umístění a forma dat a odpovědné osoby.

Příklad zdrojů dat:

- zemědělské stroje (sklízecí mlátičky, postřikovače, traktory),
- IoT senzory a meteostanice,
- administrativní agendy (hnojení, POR, účetnictví),
- státní registry a veřejné služby (LPIS, ČMSCH, SZIF),
- laboratorní rozborů (půda, krmivo, mléko),
- satelitní a dálková data.

3. krok – Plán

Vytvořené plány správy dat musí být také udržovány v rámci nepřetržitého procesu, jehož cílem je zohlednit změny v technologiích, legislativě a ve využívání dat. (87,92,93) Při vytváření samotného plánu správy dat je třeba zohlednit několik klíčových aspektů. (52,87,92,93)

- Základní informace o datech (projekt nebo oblast dat, zkratka, klíčová slova, stručný popis, správce dat, kontaktní údaje atd.)
- Zdroj a charakteristika dat (zdroj dat, typ dat, formát dat, pojmenování souborů atd.)
- Metadata (základní metadata, speciální formát metadat, standardy, ontologie, zásady FAIR, licence atd.)
- Ukládání dat (ukládání dat, bezpečnost, zálohování, archivace atd.)
- Etika (zpracování citlivých dat, sběr, ochrana, práva atd.)
- Náklady (náklady na pořízení dat, správu dat, ukládání atd.)

Údržba plánu správy dat vyžaduje pravidelné kontroly a aktualizace, aby byl plán stále aktuální. Vzhledem k postupu projektu nebo vývoji postupů správy dat by měl být plán odpovídajícím způsobem revidován. Školení členů týmu v oblasti osvědčených postupů správy dat je zásadní pro zajištění toho, aby si všichni byli vědomi svých rolí a odpovědností. Sledování dodržování DMP a provádění auditů pomáhá zajistit dodržování protokolů správy dat. Přizpůsobení DMP novým požadavkům a informovanost o nových standardech a technologiích zajišťuje, že plán zůstává.

4. krok – Realizace

Realizace spočívá v uvedení DMP do praxe: nastavení pravidel ukládání, přístupů, bezpečnosti, zálohování a sdílení dat.(53) Součástí je také pravidelná kontrola, školení pracovníků a revize plánu. (82,87,92,93)

Konkrétní postupy a nástroje jsou charakterizovány v následujících kapitolách.

2.4 Nástroje pro ukládání dat

Špatné nakládání s daty může mít různé podoby a často vede k jejich ztrátě, poškození nebo neoprávněnému přístupu. (82,87,92,93) Typickým příkladem je ukládání citlivých dat na nezabezpečené *flash disky*, které lze snadno ztratit nebo odcizit. Podobně rizikové je ponechání důležitých souborů pouze na lokálním disku bez zálohy – při selhání počítače nebo napadení *ransomwarem* mohou být data nenávratně ztracena. Velmi častou chybou je také posílání důvěrných dokumentů *nešifrovaným e-mailem*, kde mohou být zachyceny nebo omylem odeslány nesprávnému příjemci. Dalším problémem je ukládání více verzí téhož souboru na různá místa, což vede k nepořádku, nekonzistenci a práci se zastaralými informacemi. Celkově jde o situace, kdy data nejsou chráněna, nejsou zálohována, nejsou správně sdílena ani řízena – a tím ztrácejí svoji spolehlivost a bezpečnost. Klíčové prvky pro ukládání dat zahrnují především správnou archivaci a zálohování, které chrání data před ztrátou, poškozením nebo kybernetickými útoky. Archivace zajišťuje dlouhodobé uložení dat, která již nejsou aktivně používána, ale je nutné je uchovávat, zatímco zálohování vytváří pravidelné kopie důležitých souborů pro rychlou obnovu v případě havárie. Stejně důležité je jasné a logické uspořádání dat, které umožňuje snadné vyhledávání a zabraňuje chaosu; patří sem struktura složek, jednotné názvy souborů a kategorizace. Standardizace formátů a postupů pak zajišťuje konzistenci napříč celou organizací. Velkou roli hrají také metadata, tedy informace o datech, která pomáhají pochopit jejich účel, původ a aktuálnost. Součástí správné organizace je také zachování kvality dat – přesnosti, úplnosti a aktuálnosti – aby byla vždy použitelná pro svůj účel. Důležitým prvkem je i vhodné nastavení bezpečnosti a přístupových práv, aby k datům měli přístup pouze oprávnění uživatelé. Nakonec nesmí chybět řízení verzí a dokumentace procesů, díky kterým je práce s daty přehledná, bezpečná a dlouhodobě udržitelná.

Tato metodika doporučuje jako základní formu ukládání dat rozlišovat dva hlavní způsoby – souborové systémy a datové platformy (repozitářový přístup), které pokrývají jak běžné potřeby práce se soubory, tak pokročilejší požadavky na správu a zpracování dat. Souborové systémy jsou finančně méně náročné a hodí se pro základní práci se soubory, jejich sdílení a běžné firemní využití. Umožňují jednoduchou organizaci dat do složek, rychlé ukládání a přímý přístup uživatelů k dokumentům. Oproti tomu datové platformy (např. databázové systémy, datová jezera, cloudové datové sklady) nabízejí pokročilé funkce, jako je

centralizovaná správa, automatizace, analýza dat ve velkém rozsahu a lepší škálovatelnost, ale bývají finančně i provozně náročnější.

2.4.1 Souborové systémy

Souborové systémy představují jednodušší a finančně méně náročný způsob ukládání dat, který je vhodný pro běžné dokumenty (ukládání dat do souborů a adresářů), sdílené složky a administrativní agendu, přičemž klíčové je důsledné dodržování pravidel správného ukládání – tedy jasná a předem stanovená struktura složek, jednotné názvy souborů a pravidelná kontrola toho, zda jsou dokumenty uloženy na správném místě a ve správném formátu. (82,87,92,93) Pro zachování bezpečnosti i dlouhodobé dostupnosti dat je nezbytná archivace, která slouží k uchování starších nebo již neaktivních dokumentů, a také spolehlivé a pravidelné zálohování umožňující obnovu ztracených či poškozených souborů. (82,87,92,93) Zálohování může probíhat jak lokálně, například na fyzických úložištích nebo centrálních firemních zařízeních, tak také prostřednictvím online služeb, které ukládají kopie dat mimo fyzické pracoviště a tím zvyšují odolnost vůči ztrátě. Kombinace lokálního a vzdáleného zálohování poskytuje nejvyšší úroveň bezpečnosti, protože spojuje rychlý přístup k místním kopiím s robustní ochranou dat uložených mimo organizaci. (82,93) Důsledná kontrola správného ukládání, spolu s pravidelnými zálohami a kvalitně nastavenou archivací, je proto základním předpokladem bezpečného, stabilního a dlouhodobě udržitelného souborového systému. (82,93)

Aby byl souborový systém bezpečný, přehledný a dlouhodobě funkční, je nutné zavést jasné definované postupy a pravidla. Základem je vytvoření standardizované struktury složek, která přesně určuje, kam se ukládají jednotlivé typy dokumentů. (82,87,92,93) Tuto strukturu je potřeba doplnit závaznými pravidly pro pojmenovávání souborů a verzování, aby bylo zajištěno, že dokumenty jsou snadno dohledatelné a nezaměnitelné. Součástí metodiky musí být také pravidelná kontrola správnosti ukládání – například měsíční revize, při níž se ověřuje, zda jsou dokumenty na správném místě, zda se neduplikují a zda je dodržován stanovený standard. (82,93)

Pro dlouhodobou dostupnost je nutné zavést jasná pravidla pro archivaci dat, tedy přesun starších nebo neaktivních dokumentů do zvláštního archivu se stabilní strukturou. Archiv musí být přístupný pouze oprávněným osobám a uchovávané dokumenty by měly být pravidelně revidovány. Nedílnou součástí metodiky je také zálohovací strategie, která musí zahrnovat jak

lokální zálohování (externí disk, NAS – např. Synology nebo QNAP, nebo systémové nástroje typu Windows File History či macOS Time Machine), tak cloudové zálohování pomocí služeb jako Google Drive, OneDrive, Dropbox, iCloud, Backblaze, Acronis nebo Amazon S3. (94) Doporučeným standardem je model 3-2-1, tedy mít tři kopie dat, na dvou různých typech úložiště, z toho minimálně jednu mimo fyzické pracoviště. (94–100)

Dále je také důležité definovat odpovědnosti, například kdo provádí kontrolu správného ukládání, kdo spravuje archiv a kdo monitoruje úspěšnost záloh.(82,87,92,93) Samostatná část má být věnována bezpečnosti, zejména řízení přístupových práv, šifrování citlivých dat a pravidelnému testování obnovy dat, aby se ověřilo, že zálohy jsou skutečně použitelné. Zavedením těchto kroků a jejich důsledným dodržováním lze dosáhnout bezpečného, přehledného a robustního systému ukládání dat. (82,95,100–102)

2.4.2 Datové repositáře

Druhý způsob je ukládat dat do specializovaných datových repositářů. Slouží jako centralizovaná úložiště, která zajišťují systematické ukládání, správu a dlouhodobé uchovávání výzkumných dat. Jejich hlavní přínos spočívá v ochraně cenných dat před ztrátou či degradací a ve zvyšování efektivity vědecké práce tím, že umožňují snadný přístup a sdílení informací mezi výzkumníky a institucemi. (103–106)

Jednou z hlavních výhod datových repositářů je jejich schopnost standardizovat datové formáty a metadata. Tato standardizace usnadňuje integraci dat z různých zdrojů a zvyšuje jejich použitelnost. Díky tomu jsou data nejen dostupná, ale také připravená k dalším analýzám, což je zásadní pro pokročilé analytické procesy, jako je strojové učení nebo *data mining*.

Datové repositáře poskytují robustní ochranu před kybernetickými hrozbami a neoprávněným přístupem. Bezpečnostní opatření, jako je šifrování nebo řízení přístupu, zajišťují, že data zůstávají chráněná a důvěrná. Tyto mechanismy jsou nezbytné pro zajištění souladu s legislativou a požadavky poskytovatelů financí na správu a sdílení dat.

Díky strukturovanému prostředí, které datové repositáře nabízejí, podporují také aplikace pokročilých technologií, jako jsou strojové učení nebo analytika velkých dat. Umožňují výzkumníkům provádět hlubší analýzy a objevovat nové vzorce a souvislosti, což vede k dalšímu rozvoji vědy a technologií. (103–105)

2.4.3 Organizace dat

Při zpracování dat je třeba rozlišit data do dvou kategorií: primární data a sekundární data. (107)

Primární data: jedná se o data, která tvoří obsah datové platformy. Tedy o data z jednotlivých senzorů a dalších datových zdrojů. u těchto dat je nutné zajistit neměnnost v čase (zajištění integrity).

Z hlediska dostupnosti jsou primární data dělena do tří kategorií. (108)

- Aktuálně zpracovávaná data – dostupná v reálném čase v rámci aktuálně zpracovávaných datových sad v průběhu řešení projektu;
- Aktuální data – data dostupná online, zpravidla po ukončení projektu po dobu vyžádané online dostupnosti;
- Archivní data – data dostupná na vyžádání obnovou z archivu.

Sekundární data tvoří provozní data systému nutné pro běh datové platformy a slouží pro administrátory platformy. (107)


Základním prvkem organizace dat jsou **datové projekty** (např. divize podniku), které obsahují více **datových kolekcí**, například data z meteostanic. Každá datová kolekce zahrnuje tzv. *raw data*, tedy data v podobě, v jaké byla získána či naměřena, a také zpracovaná data, která představují výsledky různých analýz a modelů. (106–108) Všechny datové sady jsou doplněny o metadata, dokumentaci k datům a odkazy na analytické a vizualizační nástroje, které umožňují jejich efektivní využití a interpretaci.

2.4.4 Návrh architektury datové platformy

Webový portál funguje jako vstupní brána uživatelů do datové platformy. Umožňuje přístup jak k samotným datům, tak k jejich metadatům. Díky intuitivnímu uživatelskému rozhraní poskytuje snadnou navigaci a efektivní způsob, jak se dostat k požadovaným informacím. (30,109)

Datový katalog nabízí rozhraní pro procházení a vyhledávání *datasetů*. Obsahuje pokročilé funkce, jako je strojové prohlížení a sdílení informací z katalogu. Tyto funkce umožňují uživatelům snadno filtrovat, třídit a analyzovat dostupné datové zdroje podle různých kritérií. (30,109)

Komunikační rozhraní (API) umožňuje integraci externích datových zdrojů, jako jsou zařízení IoT. Podporuje různé technologie připojení, včetně LoRaWAN (Long Range Wide Area Network) a 5G (110) , což zajišťuje vysokou flexibilitu a kompatibilitu s moderními technologiemi. Důraz je kladen na robustní bezpečnostní opatření, která chrání data před neoprávněným přístupem a ztrátou. (101,111)



Obrázek 4 - moduly datové platformy

2.5 Nástroje pro analytiku

Nástroje pro datovou analytiku lze rozdělit do několika hlavních kategorií podle jejich účelu, funkcionality a způsobu práce s daty. Níže je přehled nejčastěji používaných nástrojů a platforem:

Nástroje pro vizualizaci a reporting

Tyto nástroje se zaměřují na přehledné zobrazování dat pomocí grafů, tabulek a interaktivních dashboardů. (112)

Příklady:

- **Power BI** (Microsoft) – propojení s MS produkty, snadná tvorba interaktivních přehledů. (113)

- **Tableau** – pokročilé vizualizace a práce s velkými daty. (114)
- **Grafana** – monitorování a vizualizace dat v reálném čase. (115)
- **Google Data Studio** (Looker Studio) – cloudový nástroj pro vizualizaci dat z Google ekosystému. (116)

Nástroje pro statistickou a pokročilou analytiku

Umožňují detailní analýzu dat, predikce, modelování a práci s algoritmy strojového učení.

Příklady:

- **R** – programovací jazyk zaměřený na statistiku a datovou vědu. (117)
- **Python** (s knihovnami jako pandas, NumPy, scikit-learn, TensorFlow) – flexibilní a výkonný nástroj pro analytiku a umělou inteligenci. (118)
- **SPSS** (IBM) – specializovaný software pro statistickou analýzu. (119)
- **SAS** – robustní analytická platforma využívaná zejména ve velkých firmách. (120)

Databázové a ETL nástroje

Slouží ke sběru, transformaci a ukládání dat, tedy k jejich přípravě pro analýzu. Příklady:

- **SQL Server, PostgreSQL, MySQL** – relační databáze pro ukládání a dotazování dat. (121–123)
- **Apache Hadoop, Spark** – zpracování velkých objemů dat (Big Data). (124,125)
- **Talend, Alteryx, Pentaho** – ETL nástroje pro integraci a čištění dat. (126–128)

Geografické a prostorové analytické nástroje

Zaměřují se na práci s geografickými daty, mapami a prostorovými vztahy.

Příklady:

- **ArcGIS, QGIS** – profesionální GIS systémy pro prostorovou analýzu. (129,130)
- **Google Earth Engine** – analýza satelitních dat a environmentálních informací. (131)

Cloudové a podnikové analytické platformy

Poskytují komplexní analytické prostředí v cloudu s podporou spolupráce, škálování a AI.

Příklady:

- **Azure Synapse Analytics, Google BigQuery, AWS QuickSight** – cloudové služby pro ukládání, zpracování a analýzu dat. (132–134)
- **Databricks** – platforma pro zpracování velkých dat a strojové učení. (135)

Využití v zemědělství

V zemědělském podniku tyto nástroje pomáhají sledovat výnosy, počasí, půdní parametry, náklady a vývoj produkce. Díky integraci dat z různých zdrojů (senzory, drony, ekonomické systémy) podporují precizní zemědělství a umožňují lépe plánovat, optimalizovat vstupy a přijímat informovaná rozhodnutí.

Dashboard (řídící panel)

Dashboard je přehledná vizuální obrazovka, která zobrazuje *klíčové ukazatele výkonnosti* (KPI), metriky a data z různých zdrojů na jednom místě. Jeho cílem je umožnit rychlé pochopení aktuální situace a podporu rozhodování. (112,113) v praxi může dashboard obsahovat:

- grafy (sloupcové, koláčové, spojnicové),
- tabulky s přehledem výkonu,
- mapy (např. výnosy na pozemcích),
- indikátory stavu (např. teploty, vlhkosti, náklady).

Dashboards se používají v nástrojích jako Power BI, Grafana, Tableau či QGIS, a mohou zobrazovat data v reálném čase nebo z historických záznamů.

V zemědělství například dashboard může ukazovat aktuální vlhkost půdy, předpověď počasí, vývoj výnosů či náklady na hnojiva.

Alerting systém (systém upozornění)

Alerting systém je mechanismus, který automaticky upozorňuje uživatele na důležité události, změny nebo problémy v datech.

Jeho hlavním účelem je včasná reakce – tedy varovat, když nějaký ukazatel překročí nastavenou hranici (tzv. threshold). (136–147)

Příklady použití:

- v zemědělství může alert upozornit, že vlhkost půdy klesla pod kritickou úroveň,
- v ekonomice podniku může signalizovat, že náklady na hnojiva přesáhly plán,
- v technických systémech může varovat před poruchou senzoru nebo výpadkem.

Alerting systémy jsou často integrované právě do nástrojů jako Grafana, Power BI nebo SCADA systémy, a mohou zasílat upozornění formou e-mailu, SMS, nebo notifikace.

Vybrané dashboard nástroje a alerting systémy

- **Grafana**

Grafana je *open-source* platforma pro monitorování, analýzu a vizualizaci dat. Umožňuje uživatelům vytvářet přehledné dashboardy, které zobrazují klíčové metriky v reálném čase. (136–138) Grafana podporuje širokou škálu datových zdrojů, mezi které patří například Prometheus, InfluxDB, MySQL, PostgreSQL, Elasticsearch, Google Sheets, CSV soubory, AWS CloudWatch, Microsoft SQL Server, či Azure Monitor. Díky tomu lze propojit technická, provozní i ekonomická data do jednoho centralizovaného rozhraní.

V kontextu zemědělského podniku umožňuje Grafana například sledovat stav plodin, půdní a meteorologické podmínky či spotřebu energií a vstupů. Na základě těchto vizualizovaných dat mohou manažeři rychleji reagovat na změny a činit přesnější rozhodnutí, která vedou k efektivnějšímu hospodaření.



Obrázek 5- příklad dashboardu zdroj - https://www.reddit.com/r/grafana/comments/cjed7e/farm_dashboard/

- **PowerBI**

Power BI je moderní nástroj od společnosti Microsoft určený pro analýzu a vizualizaci dat. Umožňuje vytvářet interaktivní reporty a dashboards, které zjednodušují práci s daty a podporují datově řízené rozhodování. (139,140) Power BI podporuje širokou škálu datových zdrojů, včetně Excelu, SQL databází, SharePointu, Azure, Google Analytics, CSV souborů, cloudových služeb (např. Salesforce, Dynamics 365) a mnoha dalších. Data lze snadno propojovat, filtrovat a automaticky aktualizovat, což umožňuje jejich průběžné vyhodnocování.



V zemědělském podniku může Power BI pomoci například sledovat vývoj výnosů, náklady na vstupy, spotřebu pohonných hmot nebo klimatické ukazatele. Díky přehledným vizualizacím mohou vedoucí pracovníci rychle identifikovat odchylky, plánovat efektivněji a přijímat kvalifikovaná rozhodnutí, která vedou ke zvýšení produktivity a hospodárnosti.

Geografické informační systémy

GIS (*Geografické informační systémy*) jsou nástroje určené pro sběr, správu, analýzu a vizualizaci prostorových dat. (4,129,130) Umožňují pracovat s mapami, satelitními snímky, daty z GPS a dalšími geografickými informacemi, které zobrazují vztahy mezi objekty

v prostoru. GIS podporuje širokou škálu datových zdrojů, například vektorová a rastrová data, databáze (PostGIS, Oracle Spatial), webové služby (WMS, WFS), GPS měření, drony, či senzorové sítě. Díky tomu lze kombinovat různé vrstvy informací – například půdní typy, hranice pozemků, výnosové mapy nebo údaje o zavlažování.

V zemědělském podniku pomáhají GIS například při precizním zemědělství, kde umožňují detailní analýzu půdy, plánování osevních postupů či optimalizaci hnojení. Díky prostorovým datům mohou manažeři lépe porozumět variabilitě pozemků a činit přesnější rozhodnutí, která vedou ke zvýšení efektivity a udržitelnosti hospodaření.



Obrázek 6- reprezentace dat v GIS, vlastní zpracování


2.5.1 Use case – práce s daty

Obrázek 7 znázorňuje příklady různých zdrojů dat, které mohou být využívány v moderních zemědělských a monitorovacích systémech. Patří sem jak automatizované IoT senzory, které pravidelně a bez zásahu člověka sbírají údaje o prostředí, půdě či provozu techniky, tak i pokročilé měřicí přístroje, například zařízení pro gamaspektrometrii. Tyto sofistikované technologie poskytují vysoce detailní a přesná data, která mohou výrazně zlepšit přehled o stavu prostředí, podpořit rozhodování a zefektivnit řízení procesů.



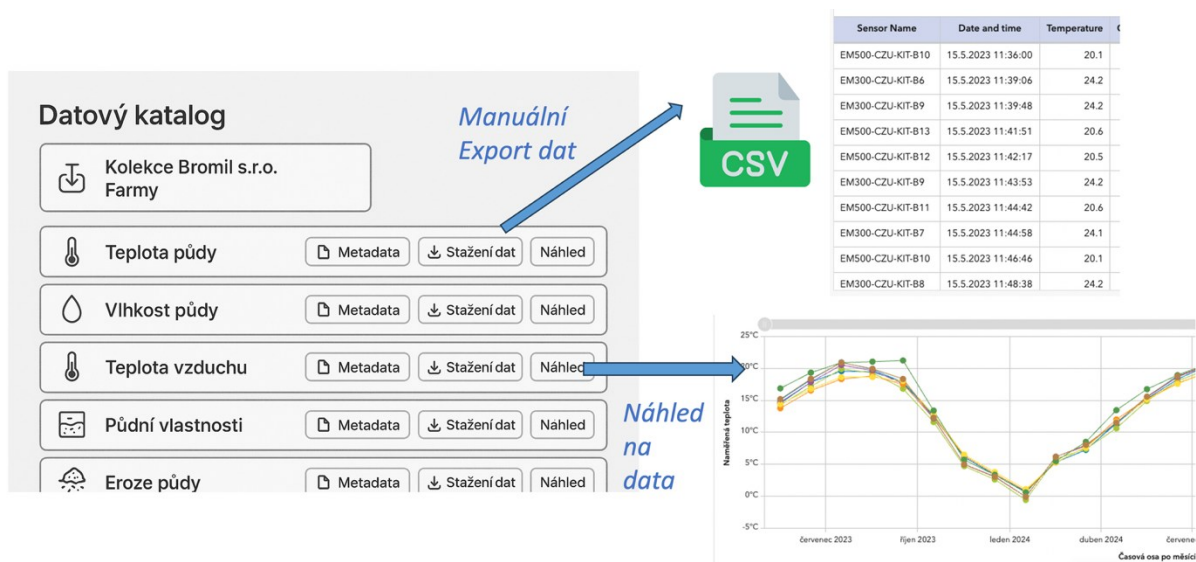
Obrázek 7 - Zdroje dat, vlastní zpracování

Obrázek 8 představuje ukázkou toho, jak mohou být data přenášena z místa jejich získání do centrální datové platformy. Přenos může probíhat plně automatizovaně pomocí specializovaných IoT sítí, například prostřednictvím technologie LoRaWAN, která umožňuje dlouhodobý a energeticky úsporný přenos dat z IoT senzorů bez nutnosti manuální obsluhy. Alternativně může být přenos realizován také manuálně, a to zejména u dat pocházejících ze specializovaných přístrojů, jako je například gamaspektrometrie, kde jsou data exportována ze softwaru zařízení ve formě souborů a následně nahrávána do datové platformy. Tímto způsobem je možné kombinovat jak automatické, tak manuální postupy a zajistit sběr dat z různorodých technologií v jednotném prostředí.



Obrázek 8 - automatizovaný přenos naměřených dat do datové platformy


Obrázek 9 představuje ukázkou datové platformy, ve které je zobrazen výpis dostupných datových kolekcí v datovém katalogu. Každá kolekce zde obsahuje odkaz na samotná data, popisná metadata a také možnost rychlého náhledu, který umožňuje uživateli okamžitě posoudit strukturu, obsah či kvalitu uložených informací. Tento způsob prezentace dat zjednodušuje orientaci, usnadňuje vyhledávání relevantních zdrojů a umožňuje efektivnější práci s daty napříč celou platformou.



Obrázek 9 - ukázkou katalogu datové platformy

Obrázek 10 představuje automatizovaný datový tok, který začíná u samotného zdroje dat, pokračuje jejich přenosem a uložením do datové platformy, kde dochází k jejich dalšímu zpracování a úpravám. Po provedení potřebných kroků se výsledná nebo obohacená data opět

ukládají zpět do platformy, odkud jsou následně využívána pro analýzy, vizualizace či další nástroje podporující rozhodování. Tento přístup umožňuje plynulý, spolehlivý a opakovatelný proces práce s daty, který minimalizuje manuální zásahy a zajišťuje konzistentní kvalitu celého datového řetězce.



Obrázek 10 - automatizace procesu

3 Srovnání „novosti postupů“

Aktuální období sběru dat postupně přechází do fáze jejich aktivního využití, což klade zvýšené nároky na to, jak jsou data ukládána a spravována. Aby bylo možné data efektivně analyzovat, sdílet a používat pro rozhodování, je nezbytné je ukládat bezpečně, systematicky a s ohledem na jejich budoucí využití. Správně nastavený způsob ukládání zajišťuje, že data zůstávají dostupná, přehledná, kvalitní a dlouhodobě použitelná, a zároveň umožňuje rychlý přechod od fáze sběru k reálnému přínosu pro organizaci.

Novost řešení spočívá v návrhu moderního nástroje pro podporu řízení zemědělských podniků, který reflektuje současné potřeby a technologické trendy v oblasti digitalizace zemědělství.

Cílem je umožnit efektivnější využívání dostupných informací a podpořit strategické plánování i každodenní operativní rozhodování v zemědělské praxi.

4 Popis uplatnění metodiky

Tato metodika je určena všem zemědělským podnikům, které pracují s daty a potřebují zajistit jejich správnou organizaci, uchování a dlouhodobý management. Realizace metodiky spočívá především v uplatnění kroků vycházející prezentovaného *Data Managment Planu* (DNP) (Kapitola 3.3.2). Metodika představuje dva přístupu aplikování DMP plánu, a to pomocí souborových systémů a pomocí systému datové platformy. Implementace u souborového systému je v rámci podniku relativně přímočařejší, protože probíhá v prostředí, které je již organizačně i technicky pod kontrolou společnosti. Naopak u datové platformy je často zapotřebí spolupráce se specializovanou firmou, která zajistí návrh, konfiguraci a bezpečnostní standardy odpovídající požadavkům podniku i legislativním normám. Se zavedením souvisí také vznik či úprava nových rolí v rámci organizační struktury – viz kapitola 3.3.1 – které jsou nezbytné pro správu, dohled, řízení přístupů a celkovou odpovědnost za provoz a bezpečnost daného řešení.

5 Ekonomické aspekty

Ceny komerčních cloudových služeb pro ukládání dat se obvykle odvíjejí od kapacity, rychlosti přístupu a úrovně zabezpečení. Běžné služby jako Google Drive, OneDrive či Dropbox stojí přibližně 150–300 Kč měsíčně za 1–2 TB prostoru, přičemž cena roste s vyššími nároky na kapacitu, firemní funkce nebo sdílení v týmu. u profesionálních cloudů typu AWS nebo Azure může být výsledná cena ještě vyšší, protože se účtuje nejen samotné úložiště, ale i přenosy dat, zálohování či šifrování. Ve srovnání s tím přináší NAS řešení jednorázovou počáteční investici do hardware, ale výrazně nižší dlouhodobé náklady. Navíc poskytuje plnou kontrolu nad daty, možnost rozšíření úložiště, automatizované zálohy a vyšší soukromí bez měsíčních poplatků. Pro organizace s dlouhodobými a rostoucími nároky na ukládání dat tak bývá NAS finančně i technicky výhodnější alternativou. Pokud se rozhodnete pro vlastní NAS řešení, počítejte s jednorázovou investicí. Například základní zařízení NAS (bez pevných disků) lze pořídit už od přibližně 6 000 – 10 000 Kč — pro domácí použití s 2 až 4 pozicemi na disky. Pokud k tomu přikoupíte disky, celková počáteční investice může činit třeba 10 000 – 20 000 Kč — bez měsíčních poplatků jako u cloudu.

Ekonomické aspekty – metodický záběr je hodně široký, záleží na konkrétní implementaci (co a jak bude reálně využito) spolu s velikostí podniku, takže je zde velký potenciál, ale i významné finanční rozpětí možného efektu – viz např. cloudová problematika.

Často nejde o statickou a pevně danou situaci, ale průběžně se měnící provozní podmínky (kurzy měn, cenová politika poskytovatelů, objemy ukládaných dat ,objemy zpracovávaných dat, délka licencí apod.).

Specifikovat lze náklady na SW, nasazení cloudu je nutně jen orientační, protože záleží na konkrétním poskytovateli (různé služby a ceny), které jsou navíc proměnné v čase a vzhledem k objemu dat se mohou také výrazně měnit. Náklady na lidské kapacity, které souvisí s organizačními změnami správy dat jsou na jedné straně vázány na velikost podniku a reálnou ICT infrastrukturu, která může být velmi rozdílná, na straně druhé potom vlastní strategii specifikovanou primárně v příslušném DMP (Data Management Plan).

Obecně tedy platí, že implementace metodiky v zemědělském podniku vyžaduje především organizační opatření a případné úpravy postupů při práci s daty. Odhadované náklady na zavedení metodiky, zejména na analýzu stávajících datových toků, vytvoření plánu správy dat a také nutné školení pracovníků, lze orientačně odhadnout na vyšší desítky tisíc Kč, např. 80–150 tis. Kč v závislosti na velikosti podniku a úrovni jeho digitalizace. Ekonomické přínosy lze očekávat zejména ve formě efektivnějšího využití dat při řízení výroby, snížení chybovosti při evidenci dat a optimalizaci výrobních procesů. Celkový ekonomický přínos lze orientačně odhadnout na několik stovek tisíc Kč, zde orientačně 150–400 tis. Kč ročně.

6 Seznam použité související literatury

1. Merriam-Webster. Data [Internet]. Dostupné z: <https://www.merriam-webster.com/dictionary/data>
2. Baskarada S, Koronios A. Data, Information, Knowledge, Wisdom (DIKW): a Semiotic Theoretical and Empirical Exploration of the Hierarchy and its Quality Dimension. Australas J Inf Syst [Internet]. 1. listopad 2013 [citován 25. listopad 2025];18(1). Dostupné z: <https://ajis.aaisnet.org/index.php/ajis/article/view/748>
3. Anna Sálová. Data vám pomohou, rozhodnout už se musíte sami | annacopy.cz [Internet]. 2020 [citován 26. listopad 2025]. Dostupné z: <https://annacopy.cz/data-vam-pomohou-rozhodnout-uz-se-musite-sami/>
4. Esri GIS Dictionary. Geographic Data [Internet]. Dostupné z: <https://support.esri.com/en-us/gis-dictionary/geographic-data>
5. Law Insider. Geographic Data Definition [Internet]. Dostupné z: <https://www.lawinsider.com/dictionary/geographic-data>
6. Cambridge University. time-series [Internet]. [citován 26. listopad 2025]. Dostupné z: <https://dictionary.cambridge.org/us/dictionary/english/time-series>
7. Merriam-Webster. quantitative [Internet]. [citován 26. listopad 2025]. Dostupné z: <https://www.merriam-webster.com/dictionary/quantitative>
8. Merriam-Webster. qualitative [Internet]. [citován 26. listopad 2025]. Dostupné z: <https://www.merriam-webster.com/dictionary/qualitative>
9. Cambridge University. multimedia [Internet]. [citován 26. listopad 2025]. Dostupné z: <https://dictionary.cambridge.org/dictionary/english/multimedia>
10. Wang RY, Strong DM. Beyond Accuracy: What Data Quality Means to Data Consumers. J Manag Inf Syst [Internet]. 1996 [citován 26. listopad 2025];12(4):5–33. Dostupné z: <http://www.jstor.org/stable/40398176>
11. Miller R, Whelan H, Chrubasik M, Whittaker D, Duncan P, Gregório J. a Framework for Current and New Data Quality Dimensions: An Overview. Data [Internet]. 18. prosinec 2024 [citován 26. listopad 2025];9(12):151. Dostupné z: <https://www.mdpi.com/2306-5729/9/12/151>
12. Souibgui M, Atigui F, Zammali S, Cherfi S, Yahia SB. Data quality in ETL process: a preliminary study. Procedia Comput Sci [Internet]. 2019 [citován 26. listopad 2025];159:676–87. Dostupné z: <https://linkinghub.elsevier.com/retrieve/pii/S1877050919314097>

13. Aljumaili M, Karim R, Tretten P. Metadata-based data quality assessment. *VINE J Inf Knowl Manag Syst* [Internet]. 9. květen 2016 [citován 26. listopad 2025];46(2):232–50. Dostupné z: <http://www.emerald.com/vjiks/article/46/2/232-250/377267>
14. Cambridge University. metadata [Internet]. [citován 26. listopad 2025]. Dostupné z: <https://dictionary.cambridge.org/dictionary/english/metadata>
15. Kahn MG, Brown JS, Chun AT, Davidson BN, Meeker D, Ryan PB, et al. Transparent reporting of data quality in distributed data networks. *EGEMS Wash DC* [Internet]. 2015;3(1):1052. Dostupné z: <https://pubmed.ncbi.nlm.nih.gov/25992385/>
16. Šimek P, Vaněk J, Jarolímek J, Stočes M, Vogeltanzová T. Using metadata formats and AGROVOC thesaurus for data description in the agrarian sector. *Plant Soil Environ* [Internet]. 31. srpen 2013 [citován 26. listopad 2025];59(8):378–84. Dostupné z: <http://pse.agriculturejournals.cz/doi/10.17221/261/2013-PSE.html>
17. Demestichas K, Daskalakis E. Data Lifecycle Management in Precision Agriculture Supported by Information and Communication Technology. *Agronomy* [Internet]. 26. říjen 2020 [citován 26. listopad 2025];10(11):1648. Dostupné z: <https://www.mdpi.com/2073-4395/10/11/1648>
18. Sandhu RS, Coyne EJ, Feinstein HL, Youman CE. Role-Based Access Control Models. *IEEE Comput* [Internet]. únor 1996;29(2):38–47. Dostupné z: <https://ieeexplore.ieee.org/document/485845>
19. International Organization for Standardization. ISO/IEC 27005: Information technology — Security techniques — Information security risk management [Internet]. 2018. Dostupné z: <https://www.iso.org/standard/75281.html>
20. Schneier B. Applied cryptography: protocols, algorithms, and source code in C. 20th anniversary edition. New York: Wiley; 2015. 1 s.
21. Goode A, Gilbert B, Harkes J, Jukic D, Satyanarayanan M. OpenSlide: a vendor-neutral software foundation for digital pathology. *J Pathol Inform* [Internet]. leden 2013 [citován 26. listopad 2025];4(1):27. Dostupné z: <https://linkinghub.elsevier.com/retrieve/pii/S2153353922006484>
22. Chatsuwan M, Moriwaki A, Ichinose M, Alkhalaf H. BIM–FM Interoperability Through Open Standards: a Critical Literature Review. *Architecture* [Internet]. 4. září 2025 [citován 26. listopad 2025];5(3):74. Dostupné z: <https://www.mdpi.com/2673-8945/5/3/74>
23. Butters OW, Wilson RC, Burton PR. Recognizing, reporting and reducing the data curation debt of cohort studies. *Int J Epidemiol* [Internet]. 1. srpen 2020 [citován 26. listopad 2025];49(4):1067–74. Dostupné z: <https://academic.oup.com/ije/article/49/4/1067/5866677>
24. Opara-Martins J, Sahandi R, Tian F. Critical review of vendor lock-in and its impact on adoption of cloud computing. In: International Conference on Information Society (i-

- Society 2014) [Internet]. London, United Kingdom: IEEE; 2014 [citován 26. listopad 2025]. s. 92–7. Dostupné z: <http://ieeexplore.ieee.org/document/7009018/>
25. Gamalielsson J, Lundell B, Brax C, Persson T, Mattsson A, Gustavsson T, et al. Open Source Software reference implementations for standards issued by different standards setting organisations: availability, perceptions and practices. *J Stand* [Internet]. 13. březen 2024 [citován 26. listopad 2025];3(2). Dostupné z: <https://journals.open.tudelft.nl/jos/article/view/7140>
 26. Česká republika. Zákonná definice otevřených dat [Internet]. [citován 26. listopad 2025]. Dostupné z: https://opendata.gov.cz/definition_opendata
 27. European Union. What is Open Data? [Internet]. [citován 26. listopad 2025]. Dostupné z: <https://data.europa.eu/en/dataeuropa-academy/what-open-data>
 28. European Union. What is Open Data? (eLearning Module 1) [Internet]. [citován 26. listopad 2025]. Dostupné z: <https://data.europa.eu/elearning/en/module1/#/id/co-01>
 29. Dr Marta Teperek, Office of Scholarly Communication Cambridge. Open Data – moving science forward or a waste of money/time? [Internet]. 2015 [citován 26. listopad 2025]. Dostupné z: <https://unlockingresearch-blog.lib.cam.ac.uk/open-data-moving-science-forward-or-a-waste-of-money-time/>
 30. Open Knowledge Foundation. CKAN Documentation [Internet]. 2025 [citován 2. prosinec 2025]. Dostupné z: <https://docs.ckan.org/en/2.11/>
 31. Berners-Lee T, community OD. 5 Star Open Data — a 5-star deployment scheme for Open Data [Internet]. [citován 26. listopad 2025]. Dostupné z: <https://5stardata.info/en/>
 32. European Union - Directorate-General for Communication. Food safety in the EU [Internet]. Dostupné z: https://european-union.europa.eu/priorities-and-actions/actions-topic/food-safety_en
 33. Kar S, Garin V, Kholová J, Vadez V, Durbha SS, Tanaka R, et al. SpaTemHTP: a Data Analysis Pipeline for Efficient Processing and Utilization of Temporal High-Throughput Phenotyping Data. *Front Plant Sci* [Internet]. 20. listopad 2020 [citován 13. listopad 2025];11:552509. Dostupné z: <https://www.frontiersin.org/articles/10.3389/fpls.2020.552509/full>
 34. Beegle K, Carletto C, Himelein K. Reliability of recall in agricultural data. *J Dev Econ* [Internet]. květen 2012 [citován 13. listopad 2025];98(1):34–41. Dostupné z: <https://linkinghub.elsevier.com/retrieve/pii/S0304387811000939>
 35. Tantalaki N, Souravlas S, Roumeliotis M. Data-Driven Decision Making in Precision Agriculture: The Rise of Big Data in Agricultural Systems. *J Agric Food Inf* [Internet]. 2. říjen 2019 [citován 13. listopad 2025];20(4):344–80. Dostupné z: <https://www.tandfonline.com/doi/full/10.1080/10496505.2019.1638264>

36. Baldin M, Breunig T, Cue R, De Vries A, Doornink M, Drevenak J, et al. Integrated Decision Support Systems (IDSS) for Dairy Farming: a Discussion on How to Improve Their Sustained Adoption. *Animals* [Internet]. 7. červenec 2021 [citován 13. listopad 2025];11(7):2025. Dostupné z: <https://www.mdpi.com/2076-2615/11/7/2025>
37. Trapanese L, Hostens M, Salzano A, Pasquino N. Short review of current limits and challenges of application of machine learning algorithms in the dairy sector. *Acta IMEKO* [Internet]. 15. březen 2024 [citován 13. listopad 2025];13(1):1–7. Dostupné z: <https://acta.imeko.org/index.php/acta-imeko/article/view/1725>
38. Jarolínek J, Samek J, Šimek P, Stočes M, Vaněk J, Pavlík J. Information sources in agriculture. *Plant Soil Environ* [Internet]. 17. říjen 2024 [citován 10. listopad 2025];70(11):712–8. Dostupné z: <http://pse.agriculturejournals.cz/doi/10.17221/361/2024-PSE.html>
39. Farm Data Principles Ltd. Farm Data Principles [Internet]. [citován 26. listopad 2025]. Dostupné z: <https://farmdataprinciples.com/news/what-we-mean-when-we-say-farm-data>
40. Zákon č. 89/1995 Sb., Zákon o státní statistické službě. Zákon č. 89/1995 Sb., Zákon o státní statistické službě [Internet]. 1995. Dostupné z: <https://www.e-sbirka.cz/sb/1995/89/2003-01-01?f=Z%C3%A1kon%20%C4%8D.%2089%2F1995%20Sb.&zalozka=text>
41. Eurostat. Structural Business Statistics (SBS) — Metadata (ESMS) [Internet]. [citován 26. listopad 2025]. Dostupné z: https://ec.europa.eu/eurostat/cache/metadata/en/sbs_esms.htm
42. Eurostat. Protocol on impartial access to Eurostat data for users [Internet]. [citován 26. listopad 2025]. Dostupné z: <https://ec.europa.eu/eurostat/about-us/impartiality-protocol>
43. European Commission. Big Data ecosystem stakeholders [Internet]. [citován 26. listopad 2025]. Dostupné z: <https://dataeconomy.eu/stakeholders/#page-content>
44. Eurostat. European Statistics Code of Practice [Internet]. 2017 [citován 26. listopad 2025]. Dostupné z: <https://ec.europa.eu/eurostat/web/quality/european-quality-standards/european-statistics-code-of-practice>
45. European Commission. Agri-Food Data Portal [Internet]. [citován 26. listopad 2025]. Dostupné z: <https://agridata.ec.europa.eu/hub/>
46. Food and Agriculture Organization of the United Nations. FAOSTAT [Internet]. [citován 26. listopad 2025]. Dostupné z: <https://www.fao.org/home/en/>
47. Food and Agriculture Organization of the United Nations. FAOLEX — Legislative and policy database on food, agriculture and natural resources [Internet]. [citován 26. listopad 2025]. Dostupné z: <https://www.fao.org/faolex/background/en/>

48. European Union. Open data in the agricultural sector [Internet]. 2019 [citován 26. listopad 2025]. Dostupné z: <https://data.europa.eu/en/publications/datastories/open-data-agricultural-sector>
49. Food and Agriculture Organization of the United Nations. Open Data Licensing for Statistical Databases [Internet]. 2019 [citován 26. listopad 2025]. Dostupné z: <https://openknowledge.fao.org/handle/20.500.14283/ca7570en>
50. European Union. Directive (EU) 2019/1024 on open data and the re-use of public sector information [Internet]. 2019 [citován 26. listopad 2025]. Dostupné z: <https://eur-lex.europa.eu/legal-content/EN/TXT/?uri=CELEX:32019L1024>
51. Kumar P, Hendriks T, Panoutsopoulos H, Brewster C. Investigating FAIR data principles compliance in Horizon 2020 funded agri-food and rural development multi-actor projects. *Agric Syst* [Internet]. 2023;230:103822. Dostupné z: <https://www.sciencedirect.com/science/article/pii/S0308521X23002275>
52. Library of the Czech Academy of Sciences. Data Management – Open and FAIR Data [Internet]. [citován 27. listopad 2025]. Dostupné z: <https://openscience.lib.cas.cz/en/open-fair-data/data-management/>
53. FAO AIMS. Guidelines on FAIR Data Management in Horizon 2020 [Internet]. [citován 27. listopad 2025]. Dostupné z: <https://aims.fao.org/news/guidelines-fair-data-management-horizon-2020>
54. Wiseman L, al et. Farmers and their data: An examination of data sharing attitudes and practices in agriculture. *NJAS – Wagening J Life Sci* [Internet]. 2019;90–91:100315. Dostupné z: <https://www.sciencedirect.com/science/article/pii/S1573521418302616>
55. Top J, Janssen S, Boogaard H, Knapen R, Şimşek-Şenel G. Cultivating FAIR principles for agri-food data. *Comput Electron Agric* [Internet]. 2022;196:106909. Dostupné z: <https://www.sciencedirect.com/science/article/pii/S0168169922002265>
56. World Meteorological Organization. WMO Unified Data Policy Resolution [Internet]. 2021 [citován 26. listopad 2025]. Dostupné z: <https://wmo.int/wmo-unified-data-policy-resolution-res1>
57. Chamorro-Padial J, others. a systematic review of open data in agriculture. *Comput Electron Agric* [Internet]. 2024;215:108441. Dostupné z: <https://www.sciencedirect.com/science/article/pii/S0168169924001662>
58. Met Office. Open Data Policy [Internet]. 2024 [citován 26. listopad 2025]. Dostupné z: <https://www.metoffice.gov.uk/policies/open-data-policy>
59. OpenWeather. OpenWeather API [Internet]. [citován 26. listopad 2025]. Dostupné z: <https://openweathermap.org/>
60. LPIS - Státní zemědělský intervenční fond [Internet]. [citován 17. prosinec 2025]. Dostupné z: <https://szif.gov.cz/cs/lpis>

61. Šarapatka B, Bednář M, editoři. Degradation and Revitalization of Soil and Landscape [Internet]. First edition. Olomouc: Palacký University in Olomouc; 2017. Dostupné z: https://www.mdpi.com/journal/sustainability/special_issues/Degradation_Revitalization_Soil_Landscape
62. ČMSCH. o společnosti - ČMSCH, a.s. [Internet]. [citován 26. listopad 2025]. Dostupné z: <https://www.cmsch.cz/o-spolecnosti>
63. ÚKZÚZ. JUDPOR – Systém evidence přípravků na ochranu rostlin [Internet]. 2025. Dostupné z: <https://ukzuz.gov.cz/public/portal/ukzuz/pripravky-na-or>
64. ÚKZÚZ. JUDÉH – Jednotné úložiště dat evidence hnojení [Internet]. 2025. Dostupné z: <https://ukzuz.gov.cz/public/portal/ukzuz/hnojiva-a-puda/registrace-hnojiv>
65. Český statistický úřad. Metodika statistiky živočišné výroby [Internet]. 2025. Dostupné z: <https://csu.gov.cz/metodika-statistiky-zivocisne-vyroby>
66. Stočes M, Šimek P, Pavlík J. Metadata Formats for Data Sharing in Science Support Systems. Agris -Line Pap Econ Inform [Internet]. 30. září 2017 [citován 10. listopad 2025];9(3):61–9. Dostupné z: <http://online.agris.cz/archive/2017/03/06>
67. Stočes M, Kánská E, Šimek P, Vaněk J. Enriched Data Sharing Methodology. Agris -Line Pap Econ Inform [Internet]. 30. červen 2018 [citován 10. listopad 2025];10(2):85–92. Dostupné z: <http://online.agris.cz/archive/2018/2/08>
68. Vyhláška č. 377/2013 Sb., Vyhláška o skladování a způsobu používání hnojiv. Vyhláška č. 377/2013 Sb., Vyhláška o skladování a způsobu používání hnojiv [Internet]. 2013. Dostupné z: <https://www.e-sbirka.cz/sb/2013/377/2025-07-15?zalozka=text>
69. Vyhláška č. 132/2018 Sb., Vyhláška o přípravcích a pomocných prostředcích na ochranu rostlin. Vyhláška č. 132/2018 Sb., Vyhláška o přípravcích a pomocných prostředcích na ochranu rostlin [Internet]. 2018. Dostupné z: <https://www.e-sbirka.cz/sb/2018/132/2022-07-01?zalozka=text>
70. Zákon č. 154/2000 Sb., Zákon o šlechtění, plemenitbě a evidenci hospodářských zvířat a o změně některých souvisejících zákonů (plemenářský zákon). Zákon č. 154/2000 Sb., Zákon o šlechtění, plemenitbě a evidenci hospodářských zvířat a o změně některých souvisejících zákonů (plemenářský zákon) [Internet]. 2000 [citován 26. listopad 2025]. Dostupné z: <https://www.e-sbirka.cz/sb/2000/154?zalozka=text>
71. Zákon č. 563/1991 Sb., Zákon o účetnictví. Zákon č. 563/1991 Sb., Zákon o účetnictví [Internet]. 1991. Dostupné z: <https://www.e-sbirka.cz/sb/1991/563/2018-01-01?zalozka=text>
72. Státní zemědělský intervenční fond. Přihlášení - informace - Státní zemědělský intervenční fond [Internet]. [citován 26. listopad 2025]. Dostupné z: <https://szif.gov.cz/cs/prihlaseni-informace>

73. Státní zemědělský intervenční fond. LPIS - Státní zemědělský intervenční fond [Internet]. [citován 26. listopad 2025]. Dostupné z: <https://szif.gov.cz/cs/lpis>
74. European Commission. Regulation (EU) 2016/679 of the European Parliament and of the Council of 27 April 2016 on the protection of natural persons with regard to the processing of personal data and on the free movement of such data, and repealing Directive 95/46/EC (General Data Protection Regulation) (Text with EEA relevance) [Internet]. OJ L dub 27, 2016. Dostupné z: <http://data.europa.eu/eli/reg/2016/679/oj>
75. Regulation (EU) 2022/868 of the European Parliament and of the Council of 30 May 2022 on European data governance and amending Regulation (EU) 2018/1724 (Data Governance Act) (Text with EEA relevance) [Internet]. OJ L kvě 30, 2022. Dostupné z: <http://data.europa.eu/eli/reg/2022/868/oj>
76. Regulation (EU) 2023/2854 of the European Parliament and of the Council of 13 December 2023 on harmonised rules on fair access to and use of data and amending Regulation (EU) 2017/2394 and Directive (EU) 2020/1828 (Data Act) (Text with EEA relevance) [Internet]. pro 13, 2023. Dostupné z: <http://data.europa.eu/eli/reg/2023/2854/oj>
77. Directive 96/9/EC of the European Parliament and of the Council of 11 March 1996 on the legal protection of databases [Internet]. OJ L bře 11, 1996. Dostupné z: <http://data.europa.eu/eli/dir/1996/9/oj>
78. COPA & COGECA. EU Code of conduct on agricultural data sharing by contractual agreement [Internet]. 2020. Dostupné z: https://fefac.eu/wp-content/uploads/2020/07/eu_code_of_conduct_on_agricultural_data_sharing-1.pdf
79. Regulation (EU) 2023/2854 of the European Parliament and of the Council of 13 December 2023 on harmonised rules on fair access to and use of data and amending Regulation (EU) 2017/2394 and Directive (EU) 2020/1828 (Data Act) (Text with EEA relevance) [Internet]. pro 13, 2023. Dostupné z: <http://data.europa.eu/eli/reg/2023/2854/oj>
80. University of Hradec Králové. Research Data – Data Management Plan [Internet]. [citován 27. listopad 2025]. Dostupné z: <https://www.uhk.cz/en/university-of-hradec-kralove/about/central-departments/open-science-office-1/research-data/data-management-plan>
81. Masaryk University Library. Data Management Plan [Internet]. [citován 27. listopad 2025]. Dostupné z: <https://digitalia.phil.muni.cz/en/services/data-management-plan>
82. University of Padua. Data Management Plan Guidelines, Version 4.3 [Internet]. 2024 [citován 27. listopad 2025]. Dostupné z: https://biblio.unipd.it/biblioteca-digitale/per-chi-pubblica/documenti-e-materiali/unipd_dmp-guidelines_18-09-2024_v4-3.pdf
83. OECD. The Digitalisation of Agriculture [Internet]. 2022 [citován 27. listopad 2025]. Dostupné z: https://www.oecd.org/en/publications/the-digitalisation-of-agriculture_285cc27d-en.html

84. Yu Z, Liu H, Peng H, Dong X. Digital transformation and farm economic performance: Evidence from Chinese dairy farms. *Smart Agric Technol* [Internet]. prosinec 2025 [citován 27. listopad 2025];12:101346. Dostupné z: <https://linkinghub.elsevier.com/retrieve/pii/S2772375525005775>
85. Šermukšnytė-Alešiūnienė K, Melnikienė R. The Effects of Digitalization on the Sustainability of Small Farms. *Sustainability* [Internet]. 13. květen 2024 [citován 27. listopad 2025];16(10):4076. Dostupné z: <https://www.mdpi.com/2071-1050/16/10/4076>
86. CESSDA Training Team. CESSDA Data Management Expert Guide. 31. leden 2020 [citován 27. listopad 2025]; Dostupné z: <https://zenodo.org/record/3820473>
87. New Zealand Department of Internal Affairs. Data and Information Management – Roles and Responsibilities [Internet]. 2017 [citován 27. listopad 2025]. Dostupné z: <https://data.govt.nz/assets/Data-governance/Data-and-Information-Management-Roles-and-Responsibilities-v2.0-003.pdf>
88. NanoCommons Consortium. Roles and responsibilities in the data life cycle [Internet]. 2020 [citován 27. listopad 2025]. Dostupné z: <https://nanocommons.github.io/user-handbook/data-management/roles/>
89. UK Government. Data ownership in government [Internet]. 2023 [citován 27. listopad 2025]. Dostupné z: <https://www.gov.uk/government/publications/essential-shared-data-assets-and-data-ownership-in-government/data-ownership-in-government-html>
90. University of New South Wales. Data Governance Policy [Internet]. 2017 [citován 27. listopad 2025]. Dostupné z: <https://www.unsw.edu.au/content/dam/pdfs/governance/policy/archive/datagovernancepolicy1.1.pdf>
91. Papadiamantis A, others. Data Management and FAIRification of Research Data in Nanotechnology. *Nanomaterials* [Internet]. 2020;10(11):2253. Dostupné z: <https://www.mdpi.com/2079-4991/10/11/2253>
92. Cessda Eric. Expert Tour Guide on Data Management [Internet]. 2017 [citován 27. listopad 2025]. Dostupné z: <https://doi.org/10.5281/zenodo.3820473>
93. University of Wisconsin–Madison. Data Lifecycle [Internet]. [citován 27. listopad 2025]. Dostupné z: <https://data.wisc.edu/data-literacy/lifecycle/>
94. Digital Preservation Coalition. Digital Preservation Handbook [Internet]. 2023 [citován 27. listopad 2025]. Dostupné z: <https://www.dpconline.org/handbook>
95. Acronis International GmbH. What is the 3-2-1 backup rule? [Internet]. [citován 27. listopad 2025]. Dostupné z: <https://www.acronis.com/en/blog/posts/backup-rule/>
96. Backblaze, Inc. Backup Strategies: Why the 3-2-1 Backup Strategy is the Best [Internet]. 2024 [citován 27. listopad 2025]. Dostupné z: <https://www.backblaze.com/blog/the-3-2-1-backup-strategy/>

97. Backblaze, Inc. The 3-2-1 Backup Rule: Bulletproof Backups for Any Budget [Internet]. 2016 [citován 27. listopad 2025]. Dostupné z: <https://www.backblaze.com/blog/bulletproof-backups-budget/>
98. Backblaze, Inc. The 3-2-1 Backup Strategy: Why the 3-2-1 Backup Strategy is the Best [Internet]. [citován 27. listopad 2025]. Dostupné z: <https://www.backblaze.com/blog/the-3-2-1-backup-strategy/>
99. Backblaze, Inc. The 3-2-1 Backup Strategy [Internet]. [citován 27. listopad 2025]. Dostupné z: <https://www.backblaze.com/blog/the-3-2-1-backup-strategy/>
100. HYCU, Inc. 3-2-1 Backup Rule Explained: How It Works & Why It Matters [Internet]. 2025 [citován 27. listopad 2025]. Dostupné z: <https://www.hycu.com/blog/3-2-1-backup-rule-explained-how-it-works-why-it-matters>
101. National Institute of Standards and Technology. NISTIR 8259 – Foundational Cybersecurity Activities for IoT Device Manufacturers [Internet]. 2020 [citován 27. listopad 2025]. Dostupné z: <https://doi.org/10.6028/NIST.IR.8259>
102. Veeam Software. The 3-2-1 Backup Rule: Why It Is Still the Best Data Protection Strategy [Internet]. [citován 27. listopad 2025]. Dostupné z: <https://www.veeam.com/blog/321-backup-rule.html>
103. Mosha NF. The Utilisation of Open Research Data Repositories for Storing and Sharing Research Data by Researchers in Higher Education Institutions. *Libr Manag* [Internet]. 2023;44(8/9). Dostupné z: <https://doi.org/10.1108/LM-05-2023-0042>
104. Tschalzev A, Purucker L, Lüdtke S, Hutter F, Bartelt C, Stuckenschmidt H. Unreflected Use of Tabular Data Repositories Can Undermine Research Quality [Internet]. *arXiv*; 2025 [citován 1. prosinec 2025]. Dostupné z: <https://arxiv.org/abs/2503.09159>
105. Peters I, Kruse F. Open Research Data Repositories: Practices, Norms and Incentives. *Int J Digit Curation* [Internet]. 2018;13(1):76–92. Dostupné z: <https://asistdl.onlinelibrary.wiley.com/doi/10.1002/asi.24571>
106. Wilkinson MD, others. The FAIR Guiding Principles for Scientific Data Management and Stewardship. *Sci Data* [Internet]. 2016;3:160018. Dostupné z: <https://www.nature.com/articles/sdata201618>
107. Cessda Eric. Process Your Data [Internet]. 2017 [citován 27. listopad 2025]. Dostupné z: <https://dmeg.cessda.eu/Data-Management-Expert-Guide/3.-Process>
108. USDA National Agricultural Library. Ag Data Commons User Guide [Internet]. [citován 27. listopad 2025]. Dostupné z: <https://www.nal.usda.gov/services/agdatacommons>
109. Kleppmann M. Designing data-intensive applications: the big ideas behind reliable, scalable, and maintainable systems. First edition. Beijing Boston Farnham Sebastopol Tokyo: O'Reilly; 2017. 1 s.

110. CMC Microsystems. IoT Demonstrator for Smart Agriculture [Internet]. 2025 [citován 2. prosinec 2025]. Dostupné z: <https://www.cmc.ca/iot-demonstrator-for-smart-agriculture/>
111. Open Knowledge Foundation. CKAN 2.11 API Documentation [Internet]. 2025 [citován 2. prosinec 2025]. Dostupné z: <https://docs.ckan.org/en/2.11/api/index.html>
112. Cambridge University Press & Assessment. dashboard [Internet]. [citován 2. prosinec 2025]. Dostupné z: <https://dictionary.cambridge.org/dictionary/english/dashboard>
113. Microsoft Corporation. Introduction to dashboards for Power BI designers [Internet]. 2024 [citován 2. prosinec 2025]. Dostupné z: <https://learn.microsoft.com/en-us/power-bi/create-reports/service-dashboards>
114. Tableau Software, LLC. Tableau Help Documentation [Internet]. 2025 [citován 2. prosinec 2025]. Dostupné z: <https://www.tableau.com/>
115. Grafana Labs. Grafana Alerting [Internet]. 2024 [citován 2. prosinec 2025]. Dostupné z: <https://grafana.com/docs/grafana/latest/alerting/>
116. Google LLC. Looker Studio Help [Internet]. 2025 [citován 2. prosinec 2025]. Dostupné z: <https://support.google.com/looker-studio/>
117. R Core Team. R: a Language and Environment for Statistical Computing [Internet]. [citován 2. prosinec 2025]. Dostupné z: <https://www.r-project.org/>
118. Foundation PS. Python Programming Language [Internet]. [citován 2. prosinec 2025]. Dostupné z: <https://www.python.org/>
119. IBM Corp. IBM SPSS Statistics [Internet]. [citován 2. prosinec 2025]. Dostupné z: <https://www.ibm.com/spss>
120. SAS Institute Inc. SAS Software [Internet]. [citován 2. prosinec 2025]. Dostupné z: <https://www.sas.com/>
121. Microsoft Corporation. Microsoft SQL Server [Internet]. [citován 2. prosinec 2025]. Dostupné z: <https://www.microsoft.com/sql-server>
122. Oracle Corporation. MySQL [Internet]. [citován 2. prosinec 2025]. Dostupné z: <https://www.mysql.com/>
123. PostgreSQL Global Development Group. PostgreSQL [Internet]. [citován 2. prosinec 2025]. Dostupné z: <https://www.postgresql.org/>
124. Shvachko K, Kuang H, Radia S, Chansler R. The Hadoop Distributed File System. In: Proceedings of the 2010 IEEE 26th Symposium on Mass Storage Systems and Technologies (MSST) [Internet]. 2010. s. 1–10. Dostupné z: <https://ieeexplore.ieee.org/document/5496972>

125. Zaharia M, others. Spark: Cluster Computing with Working Sets. In: Proceedings of the 2nd USENIX Conference on Hot Topics in Cloud Computing [Internet]. 2010. s. 10. Dostupné z: <https://dl.acm.org/doi/10.5555/1863103.1863113>
126. Talend Inc. Talend Data Integration [Internet]. [citován 2. prosinec 2025]. Dostupné z: <https://www.talend.com/>
127. Alteryx, Inc. Alteryx Designer [Internet]. [citován 2. prosinec 2025]. Dostupné z: <https://www.alteryx.com/>
128. Hitachi Vantara. Pentaho Data Integration [Internet]. [citován 2. prosinec 2025]. Dostupné z: <https://www.hitachivantara.com/en-us/products/data-management-analytics/pentaho-platform.html>
129. Esri. ArcGIS [Internet]. [citován 2. prosinec 2025]. Dostupné z: <https://www.esri.com/en-us/arcgis/products/index>
130. QGIS Development Team. QGIS Geographic Information System [Internet]. [citován 2. prosinec 2025]. Dostupné z: <https://qgis.org/>
131. Google LLC. Google Earth Engine [Internet]. [citován 2. prosinec 2025]. Dostupné z: <https://earthengine.google.com/>
132. Microsoft Corporation. Azure Synapse Analytics [Internet]. [citován 2. prosinec 2025]. Dostupné z: <https://learn.microsoft.com/azure/synapse-analytics/>
133. Google LLC. Google BigQuery [Internet]. [citován 2. prosinec 2025]. Dostupné z: <https://cloud.google.com/bigquery>
134. Amazon Web Services, Inc. Amazon QuickSight [Internet]. [citován 2. prosinec 2025]. Dostupné z: <https://aws.amazon.com/quicksight/>
135. Databricks Inc. Databricks Lakehouse Platform [Internet]. [citován 2. prosinec 2025]. Dostupné z: <https://www.databricks.com/>
136. Grafana Labs. Alerting fundamentals [Internet]. 2025 [citován 2. prosinec 2025]. Dostupné z: <https://grafana.com/docs/grafana/latest/alerting/fundamentals/notifications/>
137. Grafana Labs. Configure notifications [Internet]. 2025 [citován 2. prosinec 2025]. Dostupné z: <https://grafana.com/docs/grafana/latest/alerting/configure-notifications/>
138. Grafana Labs. Phone and SMS notifications [Internet]. 2025 [citován 2. prosinec 2025]. Dostupné z: <https://grafana.com/docs/grafana-cloud/alerting-and-irm/irm/manage/notifications/phone-and-sms/>
139. Microsoft Corporation. Set data alerts in the Power BI service [Internet]. 2025 [citován 2. prosinec 2025]. Dostupné z: <https://learn.microsoft.com/en-us/power-bi/create-reports/service-set-data-alerts>

140. Metis BI. Can Power BI Send Emails? [Internet]. 2025 [citován 2. prosinec 2025]. Dostupné z: <https://www.metisbi.co.uk/blog/can-power-bi-send-emails>
141. Prometheus Authors. Alerting overview [Internet]. 2024 [citován 2. prosinec 2025]. Dostupné z: <https://prometheus.io/docs/alerting/latest/overview/>
142. Prometheus Authors. Alertmanager [Internet]. 2024 [citován 2. prosinec 2025]. Dostupné z: <https://prometheus.io/docs/alerting/latest/alertmanager/>
143. Novaspect, Inc. Alarm Management Service [Internet]. 2024 [citován 2. prosinec 2025]. Dostupné z: <https://www.novaspect.com/services/control-system-services/alarm-management/>
144. International Electrotechnical Commission. IEC 62682:2022 – Management of alarm systems for the process industries [Internet]. 2022 [citován 2. prosinec 2025]. Dostupné z: <https://webstore.iec.ch/en/publication/65543>
145. Osanaiye O, Mamman T, Aina F. An Internet of Things (IoT)-based soil moisture monitor. Int J Smart Sens Adhoc Netw [Internet]. 2021; Dostupné z: <https://ieeexplore.ieee.org/document/9904018>
146. Kumari S, others. IoT-Enabled Soil Moisture and Conductivity Monitoring System for Precision Agriculture. Sensors [Internet]. 2025;25(7):207. Dostupné z: <https://www.mdpi.com/2624-7402/7/7/207>
147. Sazzad MdM, Ahmed T, Kibria G, Khan I. IoT based soil moisture measurement and type prediction using advanced regression and machine learning models. Sci Rep [Internet]. 13. říjen 2025 [citován 17. prosinec 2025];15(1):35730. Dostupné z: <https://www.nature.com/articles/s41598-025-19444-2>

7 Seznam publikací, které předcházely metodice

Jarolínek J, Samek J, Šimek P, Stočes M, Vaněk J, Pavlík J. Information sources in agriculture. *Plant Soil Environ.* 2024;70(11):712-718. doi: 10.17221/361/2024-PSE.

Stočes, M., Vaněk, J., Jarolínek, J., Novák, V., Masner, J., Šimek, P., Kánská, E., Havránek, M., Kubata, K. and Voral, V. (2023) "Agriculture Data Platform – Institutional Data Repository – Selected Aspects", *AGRIS on-line Papers in Economics and Informatics*, Vol. 15, No. 4, pp. 127-133. ISSN 1804-1930. DOI 10.7160/aol.2023.150409.

Stočes, M., Šimek, P. and Pavlík, J. (2017) "Metadata Formats for Data Sharing in Science Support Systems", *AGRIS on-line Papers in Economics and Informatics*, Vol. 9, No. 3, pp. 61 - 69. ISSN 1804-1930. DOI 10.7160/aol.2017.090306.

Stočes, M., Kánská, E., Šimek, P. and Vaněk, J. (2018) "Enriched Data Sharing Methodology", *AGRIS on-line Papers in Economics and Informatics*, Vol. 10, No. 2, pp. 85-92. ISSN 1804-1930. DOI 10.7160/aol.2018.100208.

Stočes, M., Vaněk, J., Jarolínek, J., Novák, V., Masner, J., Šimek, P., Kánská, E., Havránek, M., Kubata, K. and Voral, V. (2023) "Agriculture Data Platform – Institutional Data Repository – Selected Aspects", *AGRIS on-line Papers in Economics and Informatics*, Vol. 15, No. 4, pp. 127-133. ISSN 1804-1930. DOI 10.7160/aol.2023.150409.

8 Jména oponentů (kteří zpracovali posudky) a názvy jejich organizací.

- Ing. Ivo Šásek, CSc.

Příloha 1: Přehled hlavních datových zdrojů pro zemědělské podniky

Název datového zdroje	Zaměření / obsah dat	Formát / přístup	Aktualizace / periodičita	Dostupnost	Přímá relevance pro ŽV
LPIS (Registr půdy)	Evidence půdních bloků a využití zemědělské půdy (katastrální hranice, plodiny, uživatelé půdy). Slouží k kontrole dotačních podmínek a plánování pěstebních opatření.	Online mapový registr (GIS) přístupný přes web a Portál farmáře. Exporty dat ve formátech XML/CSV, WMS/WFS.	Průběžná aktualizace – změny se promítají okamžitě; ortofoto cca 1× ročně.	Veřejný náhled, plný přístup pro farmáře.	Ne
BPEJ (bonitované půdně-ekologické jednotky)	Klasifikace kvality půdy (klimatický region, půdní typ, sklon). Určuje produkční potenciál a bonitu půdy.	Mapová vrstva (eKatalog VÚMOP), seznamy kódů. Webové služby.	Statická – aktualizace jen při změnách půdních podmínek.	Veřejně dostupné mapy a služby.	Ne
Ústřední evidence skotu (ČMSCH)	Centrální registr hospodářských zvířat – narození, úhyn, přesuny, porážky. Klíčová evidence pro šlechtění a zdravotní dohled.	Online systém ČMSCH, přístup přes Portál farmáře nebo mobilní aplikace.	Průběžně – lhůta 7 dnů na hlášení událostí.	Omezená – přístup jen pro chovatele a instituce.	Ano

JUDPOR (Evidence POR)	Evidence přípravků na ochranu rostlin: kdy, kde, co, kolik. Dohled nad použitím pesticidů.	Webová aplikace v Portálu farmáře, ruční zadání nebo importy.	Dávkové odesílání; celková uzávěrka 1 × ročně.	Neveřejná – přístup pro farmáře a ÚKZÚZ.	Ne
JUDÉH (Evidence hnojení)	Evidence aplikace minerálních i statkových hnojiv (datum, dávka, plodina, plocha).	Elektronická evidence v Portálu farmáře; importy ve formátu CSV/XML.	Průběžné vedení; hlášení 1 × ročně (od 2025).	Neveřejná – přístup farmář a kontrolní orgány.	Ne
Portál farmáře (eAGRI)	Integrované rozhraní pro LPIS, registr zvířat, dotace, JUDPOR, JUDÉH, podání žádostí atd.	Webový portál (eIdentita nebo certifikát); přístup ke všem evidencím na jednom místě.	Průběžné zobrazení aktuálních dat z registrů.	Omezená – přístup jen pro registrované farmáře.	Ano
ČSÚ – statistiky ŽV	Stavy hospodářských zvířat, produkce masa, mléka, intenzita chovu. Regionální a národní agregace.	Online databáze (CSV, XLS); ročenky a přehledy.	Měsíční až roční (dle ukazatele).	Veřejně dostupné na webu ČSÚ.	Ano