



# VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

## FAKULTA STROJNÍHO INŽENÝRSTVÍ

FACULTY OF MECHANICAL ENGINEERING

## ÚSTAV MECHANIKY TĚLES, MECHATRONIKY A BIOMECHANIKY

INSTITUTE OF SOLID MECHANICS, MECHATRONICS AND BIOMECHANICS

## VYUŽITÍ METOD UMĚLÉ INTELIGENCE V DIAGNOSTICE TECHNICKÝCH SOUTAV

ARTIFICIAL INTELLIGENCE AND INDUSTRY 4.0

### BAKALÁŘSKÁ PRÁCE

BACHELOR'S THESIS

### AUTOR PRÁCE

AUTHOR

Filip Kotas

### VEDOUCÍ PRÁCE

SUPERVISOR

Ing. Jiří Kovář, Ph.D.

BRNO 2021

# Zadání bakalářské práce

|                   |  |
|-------------------|--|
| Ústav:            | Ústav mechaniky těles, mechatroniky a biomechaniky |
| Student:          | <b>Filip Kotas</b>                                 |
| Studijní program: | Aplikované vědy v inženýrství                      |
| Studijní obor:    | Mechatronika                                       |
| Vedoucí práce:    | <b>Ing. Jiří Kovář, Ph.D.</b>                      |
| Akademický rok:   | 2020/21  |

Ředitel ústavu Vám v souladu se zákonem č.111/1998 o vysokých školách a se Studijním a zkušebním řádem VUT v Brně určuje následující téma bakalářské práce:

## **Využití metod umělé inteligence v diagnostice technických soustav**

### **Stručná charakteristika problematiky úkolu:**

V aktuální době zažíváme velký rozmach použití metod umělé inteligence i v oboru diagnostiky technických soustav. Tento trend je ovlivňován rozmachem a aplikací principů Průmyslu 4.0. Cílem této práce je provedení přehledové rešerše uvedené problematiky.

### **Cíle bakalářské práce:**

Proveďte rešerši používaných metod umělé inteligence v diagnostice.

Proveďte shrnutí nejpoužívanějších metod a jejich vlastností.

Vyberte jednu z nejčastěji používaných metod a popište ji, včetně jejího použití.

### **Seznam doporučené literatury:**

MITCHELL, T. M., Machine Learning, McGraw-Hill Science/Engineering/Math, 1997, ISBN: 0070428077.

BISHOP Ch. M., Pattern Recognition and Machine Learning, Springer S+M Media, 2006, ISBN: 0-38-31073-8.

Termín odevzdání bakalářské práce je stanoven časovým plánem akademického roku 2020/21

V Brně, dne

L. S.

---

prof. Ing. Jindřich Petruška, CSc.  
ředitel ústavu

---

doc. Ing. Jaroslav Katolický, Ph.D.  
děkan fakulty

## **ABSTRAKT**

Tato bakalářská práce se zabývá rešerší používanými metodami umělé inteligence v diagnostice technických soustav. První část práce je věnována rešerší používaných metod v oblasti diagnostiky technických soustav. V druhé části je uvedeno shrnutí vlastností a použití těchto metod. Závěr práce se věnuje aplikaci metody umělé neuronové sítě a hybridní metody „adaptivní neuro fuzzy inferenční systém“, jejímž základem je neuronová síť. Tato část se zabývá podrobným popisem a použitím těchto metod v reálných technických soustavách.

## **ABSTRACT**

This bachelor thesis deals with search for artificial intelligence methods used in the diagnostics of technical systems. The first part of the work is devoted to the search of used methods in the field of diagnostics of technical systems. The second part summarizes the characteristics and applications of these methods. The conclusion of the thesis deals with the application of the artificial neural network method and the hybrid method „adaptive neuro-fuzzy inference systém“, which is based on the neural network. This part deals with a detailed description and use of these methods in real technical systems.

## **KLÍČOVÁ SLOVA**

Umělá inteligence, diagnostika, technická soustava, průmysl 4.0, strojové učení, umělé neuronové sítě.

## **KEYWORDS**

Artificial intelligence, diagnostics, technical system, industry 4.0, machine learning, artificial neural networks.

## **BIBLIOGRAFICKÁ CITACE**

KOTAS, Filip. *Využití metod umělé inteligence v diagnostice technických soustav*. Brno, 2021. Dostupné také z: <https://www.vutbr.cz/studenti/zav-prace/detail/131925>. Bakalářská práce. Vysoké učení technické v Brně, Fakulta strojního inženýrství, Ústav mechaniky těles, mechatroniky a biomechaniky. Vedoucí práce Ing. Jiří Kovář, Ph.D.

## **ČESTNÉ PROHLÁŠENÍ**

Prohlašuji, že jsem tuto bakalářskou práci na téma „Využití metod umělé inteligence v diagnostice technických soustav“ vypracoval samostatně s použitím pramenů a odborné literatury uvedených v seznamu a pod dohledem Ing. Jiřího Kováře, Ph.D.

V Holešově dne 21.05.2021

.....

Filip Kotas

## **PODĚKOVÁNÍ**

Rád bych poděkoval mému vedoucímu Ing. Jiřímu Kovářovi, Ph.D. za odborné a trpělivé vedení při tvorbě této práce. Dále bych rád poděkoval rodině a přátelům za podporu během studia.

# OBSAH

|         |  |    |
|---------|--|----|
| 1       | ÚVOD.....  | 10 |
| 2       | STAV PROBLEMATIKY.....   | 11 |
| 2.1     | Historický vývoj jednotlivých metod.....                         | 11 |
| 2.2     | Využívané metody umělé inteligence.....                          | 12 |
| 2.2.1   | Model-based.....   | 12 |
| 2.2.1.1 | Kálmánův filtr.....  | 13 |
| 2.2.1.2 | Markovův model.....  | 13 |
| 2.2.1.3 | Fault trees.....   | 14 |
| 2.2.2   | Data-driven AI a strojové učení.....                             | 15 |
| 2.2.2.1 | Umělé neuronové sítě.....  | 15 |
| 2.2.2.2 | Fuzzy logika.....  | 16 |
| 2.2.2.3 | Support vector machine.....                                      | 16 |
| 2.2.2.4 | K-nearest neighbors.....   | 17 |
| 2.2.3   | Knowledge-based.....   | 18 |
| 2.2.3.1 | Bayesovské sítě.....   | 18 |
| 2.2.3.2 | Expertní systémy.....  | 19 |
| 2.2.4   | Hybridní metody.....   | 20 |
| 2.2.4.1 | Adaptivní neuro fuzzy inferenční systém.....                     | 21 |
| 3       | SHRUTÍ NEJPOUŽÍVANĚJŠÍCH METOD A JEJICH VLASTNOSTÍ.....          | 22 |
| 4       | NEJPOUŽÍVANĚJŠÍ METODA V DIAGNOSTICE.....                        | 27 |
| 4.1     | Neuronové sítě.....  | 27 |
| 4.1.1   | Přenosové funkce.....  | 28 |
| 4.1.2   | Architektura sítě.....   | 29 |
| 4.1.3   | Strojové učení neuronové sítě.....                               | 29 |
| 4.1.4   | Typy neuronových sítí.....                                       | 30 |
| 4.2     | Adaptivní neuro-fuzzy inferenční systém.....                     | 31 |
| 4.3     | Rešerše aplikace neuronových sítí a metody ANFIS.....            | 32 |
| 4.3.1   | Využití při diagnostice mechanických zařízení.....               | 32 |
| 4.3.2   | Využití při diagnostice elektrických a mechanických strojů.....  | 33 |
| 4.3.3   | Využití při diagnostice pneumatických a hydraulických zařízení.. | 35 |
| 5       | ZÁVĚR.....   | 36 |
| 6       | SEZNAM POUŽITÝCH ZDROJŮ.....                                     | 37 |



|            |                                       |           |
|------------|---------------------------------------|-----------|
| <b>7</b>   | <b>SEZNAM OBRÁZKŮ A TABULEK .....</b> | <b>46</b> |
| <b>7.1</b> | <b>Seznam obrázků.....</b>            | <b>46</b> |
| <b>7.2</b> | <b>Seznam tabulek.....</b>            | <b>46</b> |

# 1 ÚVOD

Čtvrtá průmyslová revoluce neboli Průmysl 4.0 je současný trend, který se snaží o digitalizaci a automatizaci výrobních procesů a služeb s nimi spojených. Důsledkem toho má být převzetí manuálních, fyzicky náročných a repetitivních prací počítačovými a robotickými systémy. Pomocí metod Průmyslu 4.0 dojde k úspoře času, peněz a zvýšení flexibility firem. Taktéž se očekává vznik nových pracovních míst, která však budou vyžadovat vyšší kvalifikaci zaměstnanců.

Tato změna s sebou nese také velký rozmach použití umělé inteligence, od níž se očekává schopnost analyzovat a řešit problémy či zpracovávat velký objem dat.

První myšlenky o umělé inteligenci se začaly utvářet v první polovině 20. století. Základy položil v roce 1950 Alan Turing svým Turingovým testem, který zkoumá, jestli lze testovaný stroj, program či umělou inteligenci, skutečně považovat za inteligentní. Roku 1959 pak Arthur Samuel přidal frázi strojové učení a tím konkretizoval využití umělé inteligence na automatické pochopení a vytváření algoritmů, jež se učením samy zdokonalují.

Původním záměrem však bylo, aby se umělá inteligence chovala jako myšlení člověka. Tento záměr se však ukázal jako nerealizovatelný z důvodu extrémní obtížnosti, a proto je v dnešní době zaměřena na řešení konkrétních problémů či rozvoj jednotlivých přístupů.

Stěžejním cílem této bakalářské práce je rešerše využívaných metod umělé inteligence v diagnostice technických soustav. Dalším cílem je vytvoření shrnutí vlastností a konkrétních aplikací vybraných metod. Posledním cílem v závěru práce, je zvolení nejpoužívanější metody, její podrobný popis a rešerše aplikace.

## 2 STAV PROBLEMATIKY

*Technická diagnostika je vědní a současně praktický obor zabývající se metodami a prostředky zjišťování skutečného technického stavu objektů v reálném čase, bez jejich demontáže nebo destrukce. Hlavním cílem je co nejvíce nahradit intuitivní a individuální přístup k určování technického stavu přístupem exaktním a systematickým s maximálním využitím všech relevantních informací o diagnostikovaném objektu nebo produktu. [1]*

### 2.1 Historický vývoj jednotlivých metod

Z historického hlediska se všechny metody vyvíjely samostatně a nezávisle na sobě s výjimkou hybridních systémů, které jsou kombinací více již uvedených metod.

- **Kálmánův filtr** – Byl poprvé představen v roce 1960 maďarsko-americkým matematikem Rudolfem E. Kálmánem. Využívá řadu měření v reálném čase pro odhad následujících neznámých hodnot a zpravidla vykazuje větší přesnost než metody, které jsou založené na jednom měření.
- **Markovův model** – Pojmenován po ruském matematikovi Andreji A. Markovovi, který žil na přelomu 19. a 20. století. Metoda popisuje zpravidla diskrétní stochastický (náhodný) proces, pro který platí, že pravděpodobnost přechodu do jiného stavu je závislá pouze na současném stavu.
- **Fault trees** – Analýza vytvořená H. A. Watsonem v roce 1962 je deduktivním procesem, který rozděluje selhání systému na podrobnější události jako jsou poruchy subsystémů, které mohou být za toto selhání zodpovědné. Tento proces se opakuje pro každou novou nalezenou událost, dokud nezůstanou pouze základní události bez podrobnějších popisů. [2]
- **Neuronové sítě** – Neuronové sítě mají počátek v roce 1943, kdy Warren McCulloch a Walter Pitts vytvořili první jednoduchý matematický model neuronu, který představoval teoretický model biologického neuronu. Tento model vyvolal zájem o zkoumání dané problematiky. První umělá neuronová síť (perceptron) byla představena v roce 1957 Frankem Rosenblattem. Roku 1969 však byl tento koncept zdiskreditován z důvodu neschopnosti řešit složitější problémy a zájem se odklonil k jiným metodám. Změna nastala až v roce 1986, kdy byl na neuronové sítě aplikován učící algoritmus Backpropagation, který pomocí zpětného šíření chyby značně vylepšil možnosti této metody a znovu oživil zájem o tuto metodu. [3]
- **Fuzzy logika** – Vychází z teorie fuzzy množin. Cílem bylo převést neurčitost, nedokonalost, reálného světa do matematické logiky. Základem fuzzy logiky je publikace Lotfi Zadeha z roku 1965, která je neustále rozvíjena. Poprvé byla aplikována na kontrolní systém turbíny. V současné době se využívá u domácích spotřebičů, v automobilovém průmyslu a pro řízení podzemní dráhy. [4] V diagnostice je pak hojně využívána v hybridních systémech.
- **Support vector machine** – Tato metoda byla představena Corinnem Cortesem a Vladimírem Vapnikem v roce 1995. [5] Jedná se o supervizovaný model učení, který analyzuje data používaná pro klasifikaci nebo regresní analýzu. [6]

- **K-nearest neighbors** – Statistická neparametrická klasifikační metoda, která byla po-prvé představena v roce 1951. Za autory se považuje Evelyn Fix a Joseph Hodges.
- **Bayesovské sítě** – Metoda založená na pravděpodobnostním uvažování, k jehož zobrazení využívá grafovou reprezentaci. Autorem je Judea Pearl, který jako první popsal tuto metodu v roce 1988. [7]
- **Expertní systémy** – Účelem vzniku této metody bylo napodobit rozhodovací a popisovací činnost experta v dané oblasti. První oficiální expertní systém byl představen v roce 1965 na Stanfordu Edwardem Feigenbaumem, který je označován za otce expertních systémů. Současné expertní systémy jsou výsledkem zdokonalování předchozích typů. Tento vývoj je založen zejména na nových metodách umělé inteligence (strojové učení a data mining s mechanismem zpětné vazby).
- **Adaptivní neuro fuzzy inferenční systém** – Jde o typ hybridní metody, která kombinuje umělé neuronové sítě a fuzzy inferenční systém. Vyvinuta byla začátkem 90. let minulého století.

## 2.2 Využívané metody umělé inteligence v diagnostice

V současné době lze vnímat rychlý vývoj umělé inteligence v technické diagnostice. Cílem je sledovat a zabránit selhání stroje pomocí analýzy a zpracování velkého množství informací z různých částí stroje za účelem zvýšení bezpečnosti, snížení prostojů a údržby stroje. Dříve tuto práci vykonávali experti, avšak z důvodu velkého množství dat byl tento proces příliš dlouhý na to, aby data byla relevantní.

Diagnostické metody je možné rozdělit dle práce [8] následovně:

- **Model-based**
- **Data-driven AI a strojové učení**
- **Knowledge-based**
- **Hybridní inteligence**

### 2.2.1 Model-based

Tento přístup zahrnuje metody jako Kálmánův filtr, Markovův model či analýzu fault trees. Při vytváření modelu je potřebné hlubší poznání systému, vytvořený model pak napodobuje fyzické vlastnosti systému a jeho případnou interakci s různými senzory. Při aplikaci v diagnostice se korektnost výstupu z právě vytvořeného modelu ověřuje srovnáním s naměřenými daty z telemetrie (dálkové měření) skutečného systému. [8]

### 2.2.1.1 Kálmánův filtr

Metoda implementuje pozorovatele, který využívá řadu měření v reálném čase a vytváří tak přesnější odhad následujících hodnot nežli metody založené na jediném měření. Odhad je vytvořen jako průměr předpokládaného stavu a nového měření pomocí váženého průměru. Účelem váženého průměru je, aby hodnoty s menší odhadovanou neurčitostí byly více relevantní. Celý proces se opakuje v každém časovém kroku, metoda tedy pracuje rekurzivně a pro výpočet nového stavu vyžaduje pouze poslední nejlepší odhad stavu systému, a nikoliv celou historii.

Při aplikování na zpracování signálů metoda filtruje jednotlivé hodnoty, aby rozlišila šum způsobený chybami telemetrie a hodnotami, které indikují vadné chování. Tuto filtraci zvládá v reálném čase a vykazuje spolehlivé výsledky i ve velmi hlučném prostředí, které produkuje velké množství nespolehlivých údajů. [8]


V této podobě se Kálmánův filtr využívá v lineárních systémech, u kterých předpokládá závislost výstupního signálu na vstupním neboli systém nemění své chování v čase. Pro použití v nelineárních systémech byly vyvinuty rozšíření tohoto základního typu [9]:

Rozšířený Kálmánův filtr je nelineární verze, která za pomoci použití Jacobiho matice v každém časovém kroku linearizuje odhad aktuálního průměru. Tato rozšířená verze je v dnešní době již standardní součástí navigačních systémů.

Příkladem úspěšného použití je práce [10] z roku 2018, kde autoři aplikovali tuto metodu na nelineární dynamický model letadlového motoru s poruchami v aktuátoru. Identifikování poruchy bylo založeno na datech z hydraulické soustavy.

### 2.2.1.2 Markovův model

Nejjednodušším typem je Markovův řetězec. Využívá se pro diskrétní stochastické procesy, u kterých platí, že pravděpodobnost přechodu do jiného stavu závisí pouze na současném stavu, nikoliv na stavech předchozích. Tato vlastnost se nazývá Markovova vlastnost a umožňuje popisovaný proces znázornit stavovým diagramem.



Obr. 1 – Jednoduchý diskrétní Markovův řetězec se dvěma stavy [11]

Mnohem více používaným typem je Skrytý Markovův model, který je rozšířenou verzí původního modelu. Aplikuje se v procesech, u kterých jejich stav není viditelný

pozorovatelem, ale jejich výstup, který je na tomto stavu závislý, viditelný je. [12] Různé poruchy systému jsou v něm reprezentovány uzly, které jsou spojeny hranami (přechody). Ty mají pravděpodobnostní povahu, což umožňuje vypočítat šance na přechod z jednoho stavu do druhého.

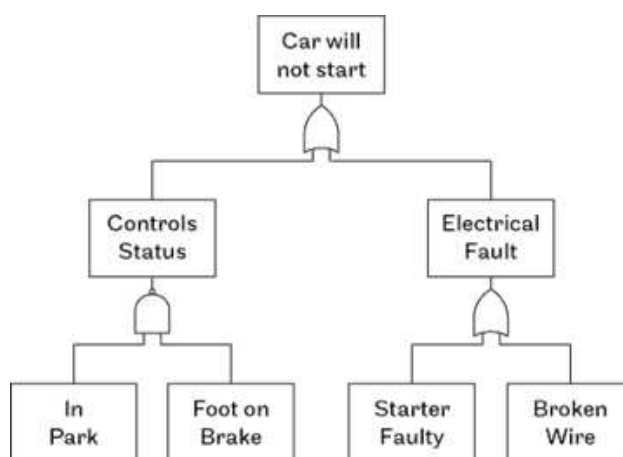
Markovovy modely se díky dobrým schopnostem predikce často uplatňují v údržbových systémech založených na podmínkách. [13] V práci [14] z roku 2017 používají autoři Skrytý Markovův model k poruchové diagnostice rotujícího stroje z vibračního signálu. Na základě výsledků simulace se vstupní rychlostí a její odpovídající poruše na zařízení, byly získány hodnoty vibračního posunutí v každé oblasti zařízení, které byly využity k nastavení modelu a následnému ověření schopnosti modelu detekovat poruchy. Aplikace dosáhla úspěšnosti 88,41 % a potvrdila podobnou míru efektivity jako neuronové sítě nebo adaptivní neuro fuzzy inferenční systém.

### 2.2.1.3 Fault trees

Analýza fault trees je jedna z nejpoužívanějších technik bezpečnostní a spolehlivostní analýzy. Jedná se o tzv. top-down dedukci selhání, při které se zkoumají nežádoucí stavy systému pomocí Booleovy logiky, která kombinuje řadu událostí nižší úrovně. [5]

Je reprezentována ve formě stromového logického diagramu obsahujícího vztahy mezi hlavní událostí (porucha systému) a jejími příčinami. Vztahy jsou popsány pomocí logických bran a symbolů. Pro sestrojení takového diagramu je nutno mít znalosti o hlavní události, protože je nutné ji analyzovat a tyto informace využít při sestrojení. [15]

Díky formě reprezentace se využívá ke grafické analýze poruchových událostí nebo ji lze použít jako diagnostický nástroj k identifikaci a nápravě příčin poruchy systému. [5]



Obr. 2 – Ukázkový diagram analýzy fault trees [16]

Ukázková aplikace je popsána v práci [17] z roku 2018, kde autoři využívají analýzu chybových stromů, pro identifikaci a opravení příčiny poruchy nakládacího stroje. Možné

příčiny si rozdělili na tři typy: chyba hardwaru, chyba řídicího systému skladování nebo chyba při naskenování kódu právě skladované baterie. Ve výsledku ji implementovali přímo do diagnostiky poruch automatické produkce a instalace napájecích baterií, čímž značně zvýšili efektivitu diagnostiky.

## 2.2.2 Data-driven AI a strojové učení

Přístup využívající techniky trénování a učení za účelem vytvoření modelu, který reprezentuje chování systému, je základem datově řízených systémů. Skupina obsahuje metody jako jsou umělé neuronové sítě, fuzzy logika, metoda podpůrných vektorů nebo k-nearest neighbors. [8] Tyto metody jsou schopny se rozhodovat a vyrovnávat se se změnami v systému v reálném čase. Nevýhodou je naprostá závislost na datech. Pro vytvoření efektivního modelu vyžadují dostatečné množství historických tréninkových dat. [18]

Strojové učení se zabývá algoritmy a technikami, které umožňují metodám umělé inteligence učit se. Během procesu učení se model snaží minimalizovat odchylku mezi skutečným a požadovaným výstupem. Tyto procesy řadíme mezi tzv. iterační (opakující se) procesy.

Za základní algoritmy učení se považují tyto tři typy:

- **Učení s učitelem** – Stejně jako v přírodě, využívá tento algoritmus zpětnou vazbu k učení. Modelu se předloží vzor, u kterého je znám předem požadovaný výsledek. Ten se porovná s výsledkem, který předloží model s aktuálním nastavením. Následně se upravují hodnoty vah či prahů v modelu tak, aby bylo dosaženo co nejmenší chyby.
- **Učení bez učitele** – U tohoto typu nejsou výsledky předem známé. Model hledá společné vlastnosti vzorů a třídí si je do skupin. Účelem je tedy spíše utřídění, vyhlazení či snížení dimenzionality vstupních dat.
- **Zpětnovazebné učení (učení posilováním)** – Jedná se o učení pomocí zpětné vazby. Model se v tomto případě učí sám reagovat na vstup, sám si volí akce tak, aby na ně byla co nejlepší zpětná vazba. Dělí se na pasivní a aktivní učení. Rozdíl je v tom, že u pasivního učení je předem dána strategie, se kterou prochází prostor, kdežto u aktivního učení si volí model tuto strategii sám.

### 2.2.2.1 Umělé neuronové sítě

Jednou z nejstarších a nejpoužívanějších metod v diagnostice jsou umělé neuronové sítě, přičemž předlohu pro její vznik tvořila neuronová síť mozku. [6] Tato síť je tvořena jednotlivými neurony, které jsou popsány matematickými modely.

Při sestavování neuronové sítě je nutno vybrat vhodný učicí algoritmus (viz. kapitola 2.2.2) a vhodnou architekturu sítě. Architekturu sítě se myslí, kolik neuronů využijeme k vytvoření sítě a jak tyto neurony propojíme. Základními typy jsou Perceptron a vícevrstvé neuronové sítě (více viz. kapitola 4.1.2).

Jedná se o velmi univerzální metodu, kterou lze nalézt v mnoha odborných pracích zabývajících se diagnostikou poruch v technických soustavách. [13] Adaptivní povaha této metody poskytuje vhodné vlastnosti pro aplikování na nelineární vztahy mezi funkcemi. Pokud je model vhodně nastaven z tréninkových dat, dokáže si při absenci části dat ze systému tato data uměle vytvořit a nadále fungovat s takřka stejnou přesností, to vše však za cenu náročného procesu učení. Problémem této sítě je však její chování, které popisujeme jako „black box“, neboli nám není známa vnitřní strukturu modelu a tento model je tak těžké interpretovat. [12]

V dnešní době se však využívají spíše její modifikace nebo hybridní systémy obsahující neuronové sítě. Její modifikace se dají rozdělit právě pomocí architektury sítě nebo učicího algoritmu, čímž vznikají různé typy neuronových sítí jako jsou: hluboké neuronové sítě, backpropagation neuronové sítě nebo konvoluční neuronové sítě (více viz. kapitola 4.1.4).

Ve výzkumu [19] využili autoři v roce 2019 metodu Konvoluční neuronové sítě. Aplikovali ji na experimentální data valivých ložisek z Case Western Reserve University. Vstupem je zde originální vibrační signál a výstupem pak přímo typ poruchy. Výsledek aplikace dosahoval úspěšnosti detekce poruch 99,41 % a překonal tak jiné metody jako třeba backpropagation neuronové sítě.

#### **2.2.2.2 Fuzzy logika**


V dnešní době je obtížné vyjádřit vztah mezi chybou a symptomem a jednoduchá dvouhodnotová logika na to již nestačí. Proto je v tomto případě mnohem vhodnější zavést fuzzy logiku k popisu poruch. [7] Fuzzy logika mění přesné uvažování na přibližné a zvyšuje tím do určité míry tolerance vady. [20] Umožňuje modelu rozhodování na základě širší shody z nečíslných a nepřesných dat a je schopna přehodnotit prahové hodnoty, u kterých se předpokládá, že se budou dynamicky měnit v průběhu pozorování. [8]

Jedná se tedy spíše o druh interpretace znalostí a pravidel než o samostatnou metodu. Stává se velmi efektivní při predikci poruch v případě, že je k dispozici velké množství údajů. Využívá se hlavně v kombinaci s jinými metodami, například je použita v metodě adaptivní neuro fuzzy inferenční systém (viz. kapitola 2.2.4.1).

#### **2.2.2.3 Support vector machine**

Jedná se o supervizovaný model učení, který analyzuje data používaná pro klasifikaci nebo regresní analýzu. [6] Úkolem této metody je nalézt takovou nadrovinu, která prostor příznaků lineárně separuje.





Obr. 3 – Příklad lineárně separovaného prostoru příznaků [21]

Pokud nastane situace, kdy prostor příznaků je lineárně separabilní jen částečně, metoda se snaží nalézt takovou nadrovinu, aby chyba klasifikace byla minimální.


V případě, že prostor není lineárně separabilní, metoda využívá jádrovou funkci, která transformuje prostor příznaků do prostoru zpravidla vyšší dimenze, ve které již lineárně separovatelný je. Nejčastější jádrové funkce jsou například: radiální bázová funkce nebo polynomická funkce.

Její použití je vhodné pro řešení problémů malé velikosti vzoru. Konkrétněji se například používá pro identifikaci poruchy v elektrických strojích nebo při modelování lineárních a nelineárních vztahů. Při identifikaci poruchy se sice neobjevuje tak často jako metoda umělých neuronových sítí, ale zase má oproti ní velmi malou výpočetní náročnost. [12]

Práce [22] z roku 2013 demonstruje použití této metody při poruchové diagnostice generátoru parní turbíny tepelné elektrárny. Model byl natrénován na vzorcích vykazujících normální stav a tři chybové stavy, konkrétně chybu stimulace páry, uvolněné ložisko a tření. Výsledky diagnostiky by měly rozlišovat právě tyto 4 stavy. Ve výsledku autoři vytvořili model, který je schopen této více-poruchové klasifikace.

#### 2.2.2.4 K-nearest neighbors

Jedná se o jednu z nejjednodušších a nejefektivnějších metod klasifikace, které se aktuálně používá. [6] Využívá funkci vzdálenosti k měření podobnosti mezi dvěma vzorky z testovaných dat nebo bodu dotazu. [23] Účelem tohoto procesu je klasifikování nových objektů do tříd. Klasifikace nového objektu závisí na datech, která se vyskytují okolo něj. Při zvolení parametru  $k$  určíme, kolik nejbližších okolních dat zahrneme do rozhodování o rozdělení nového objektu. Následně jednoduše spočítáme počet těchto dat a nový objekt zařadíme do třídy s větším počtem. Při volení parametru  $k$  je tedy vhodnější zvolit liché číslo. [24]



Obr. 4 – Jednoduchá ukázka metody *k*-nearest neighbors [24]

Dnes již existuje i modifikovaná verze této metody. Jde o odvozenou metodu, která nabízí lepší úroveň výpočtů a přesnější volení vah. Narozdíl od původní verze počítá konkrétní vzdálenost mezi novým objektem a nejbližšími daty. Tuto vzdálenost využívá pro zavedení vah, které přidávají na důležitosti datům z bližší vzdálenosti.

V práci [25] autoři porovnali modifikovanou metodu s původní metodou a modifikovaná verze dosáhla větší přesnosti při klasifikaci dat o 5-7 %.

## 2.2.3 Knowledge-based

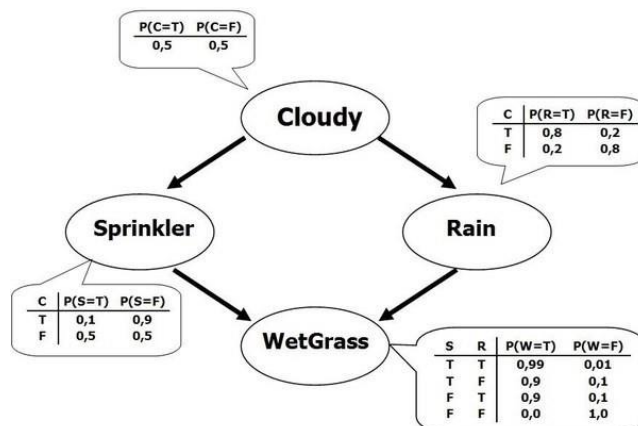
Třetí skupina využívaných metod je charakteristická tím, že je závislá na historických datech či znalostech od experta v dané problematice. [26] Všechny potřebné informace jsou v tomto systému uloženy ve formě IF-THEN pravidel. Tato databáze musí být do systému vložena nebo musí být pomocí jiné metody vytvořena automaticky. Do skupiny knowledge-based patří metody Bayesovské sítě nebo expertní systémy.

### 2.2.3.1 Bayesovské sítě

Bayesovská síť je acyklický orientovaný graf tvořený uzly a hranami. Uzly reprezentují události a hrany pak pravděpodobnostní závislosti mezi těmito událostmi. Pod pojmem událost si můžeme představit pozorovatelné veličiny, hypotézy nebo neznámé proměnné. Pokud nějaké uzly nejsou spojeny hranami, tak říkáme, že tyto uzly (či události) jsou vzájemně podmíněně nezávislé. Uzly navazující na další uzly se nazývají rodiče. [12]

Nejjednodušším způsobem sestavení sítě je, její sestavení samotným expertem. V takovém případě je potřeba dbát na přehlednost grafu a logické uspořádání událostí, kdy příčiny předcházejí efekty. Celková přehlednost grafu ve výsledku přispívá ke snazšímu vytvoření tabulky podmíněné pravděpodobnosti, která musí být u každého uzlu. Pro automatické vygenerování lze použít například lokální vyhledávač. Tato metoda může začít z prázdného grafu nebo již kompletního grafu a v každém kroku provádí pouze jednu změnu v jeho struktuře. Konkrétně přidává, odebírá nebo otáčí hranu. Pokud

se při této změně zvýší ohodnocení, které hrana představuje, tak tuto změnu zachová, v opačném případě se vrátí do starého stavu.



Obr. 5 – Příklad jednoduché Bayesovské sítě [27]

Parametry sítě musí být nastaveny pomocí učícího algoritmu z dat. Příkladem takového učícího algoritmu je maximalizace pravděpodobnosti. Tento algoritmus prochází jednotlivými uzly a hledá vhodné kandidáty na rodiče vyšetřovaného uzlu, následně vytvoří množinu kandidátů, do které jsou přidáni všichni kandidáti, kteří zvyšují ohodnocení vyšetřovaného uzlu. Přidávání končí ve chvíli, kdy se dosáhne maximálního počtu rodičů nebo již došli kandidáti navyšující ohodnocení uzlu. Algoritmus tímto způsobem maximalizuje pravděpodobnost shody mezi modelem Bayesovské sítě a daty.

V práci [28] byla tato metoda využita pro diagnostiku a identifikaci typu poruch transformátoru. Ve výsledku byla schopna úspěšně rozpoznat 9 typů poruch a 24 typů symptomů.

### 2.2.3.2 Expertní systémy

*Expertní systém je charakterizován jako počítačový program, který simuluje rozhodovací činnost experta při řešení složitých, úzce problémově zaměřených úloh.* [29]

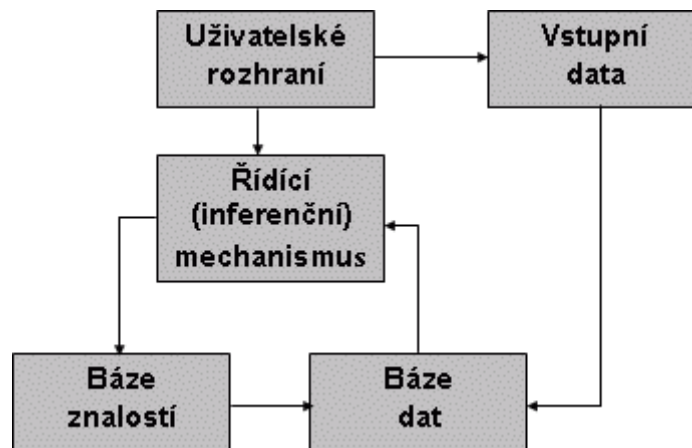
Metody umělé inteligence řeší úlohy především pomocí matematické logiky a statistiky, zatímco expert zapojuje do řešení své znalosti, intuici a zkušenosti. Expertní systém musí zvládat oba tyto přístupy.

Odlišností této metody od ostatních je, že má oddělené znalosti/data od řídicího mechanismu. Skládá se ze 4 částí: uživatelské rozhraní, báze znalostí, řídicí mechanismus a báze dat. Bázi znalostí a (inferenční) řídicí mechanismus je nutno upravit podle aplikační oblasti.

- **Uživatelské rozhraní** – Zajišťuje komunikaci mezi uživatelem a expertním systémem. Uživatel zde vkládá vstupní data, která jsou základem pro řídicí mechanismus při řešení úlohy.
- **Báze znalostí** – V bázi znalostí jsou zapsány všechny znalosti expertního systému. Tuto databázi je potřeba neustále udržovat aktuální a přehlednou. Musí tedy být vysoce modulární a dobře uspořádaná pro vyhledávání informací. Systém

musí být schopný řešit i neznámé situace. Expert by vycházel ze zkušeností. Ty se v expertním systému označují jako neurčitosti a je jim přiřazena tzv. míra neurčitosti, která je vyjádřena numerickou hodnotou.

- **Báze dat** – K úspěšnému řešení problému je potřeba, aby uživatel o něm zadal informace prostřednictvím uživatelského rozhraní. Kvalita rozhraní je kritická pro získání kvalitních informací o problému a tím i k vytvoření správného řešení. Veškerá tato vstupní data se ukládají do báze dat.
- **(Inferenční) řídicí mechanismus** – V řídicím mechanismu jsou zapsány algoritmy pro hledání řešení dané úlohy. Snaží se napodobit uvažování experta pomocí efektivního využívání poznatků a zkušeností (neurčitostí) z báze znalostí a báze dat.



Obr. 6 – Schéma expertního systému [30]

Expertní systémy rozdělujeme na pravidlové a nepravidlové, přičemž v pravidlových jsou znalosti reprezentovány pomocí pravidel IF-THEN a fuzzy logiky. Druhým typem jsou nepravidlové expertní systémy, které využívají například sémantické sítě, což je metoda grafického reprezentování znalostí.

Při diagnostice technických soustav se více využívá reprezentace znalostí na základě pravidel. Díky tomuto typu uložení dat dokáže poskytnout i řešení daného problému.

Autoři v práci [31] aplikují expertní systém pro diagnostiku poruch vibračního systému mechanického zařízení. Pro udržování aktuálnosti báze znalostí, ve které jsou znalosti reprezentovány pomocí fuzzy logiky, použili metodu neuronové sítě. Tím vytvořili efektivní metodu diagnostiky poruch vibračního systému mechanického zařízení.

## 2.2.4 Hybridní metody

Poslední skupinou jsou hybridní metody, které jsou složeny ze dvou a více již výše uvedených metod. Hybridní metoda kombinuje vlastnosti těchto metod a stává se tak komplexnější metodou.

Vznikají za účelem konkrétní aplikace, která vyžaduje kombinaci vlastností několika metod. Nezařazují se ani do jedné z výše uvedených skupin.

#### 2.2.4.1 Adaptivní neuro fuzzy inferenční systém

ANFIS (zkratka z angl. adaptive neuro-fuzzy inference system) je nejvíce přesný model ze skupiny neuro-fuzzy systémů. V podstatě se jedná o vícevrstvou neuronovou síť využívající fuzzy logiku pro interpretaci znalostí a vnitřních pravidel, díky čemuž je model efektivnější skrze odhalování informací ohledně vnitřních souvislostí mezi proměnnými konkrétního problému a je taktéž lépe interpretovatelný než klasická neuronová síť. [32] Skládá se z pěti vrstev, z nichž každá má svoji funkci (podrobný popis v kapitole 4.2).

Jeho cílem je vybudovat obecný model, který splňuje požadavky na vysokou přesnost, přičemž se vzdává řešení zahrnujících uspořádání systémových parametrů a v tomto směru se omezuje pouze rozdělení vstup-výstup.

Jelikož se dá vždy použít na místo samotné neuronové sítě, jeho využití v diagnostice technických soustav je velmi rozsáhlé. [13]

V práci [33] z roku 2017 autoři aplikují metodu ANFIS pro poruchovou diagnostiku motoru. Konkrétně testují, s jakou přesností dokáže diagnostikovat tři základní poruchy motoru: poruchu rotoru, excentricitu rotoru a poruchu statoru. Model dosáhl přesnosti 87 %.

### 3 SHRNU TÍ NEJPOUŽÍVANĚJŠÍCH METOD A JEJICH VLASTNOSTÍ

V následující tabulce je uvedeno shrnutí vlastností a rešerše aplikace výše uvedených metod v oblasti diagnostiky technických soustav.

| METODA         | VLASTNOSTI  | APLIKACE                                      | ÚČEL   | ZDROJ     |
|----------------|---|---|--|-----------|
| Kálmánův filtr | Vhodná pro použití v hlučném prostředí na lineární i nelineární systémy, je schopna pracovat v reálném čase.                                  | Nelineární dynamický model letadlového motoru | Detekce poruchy aktuátoru                                | 2018 [10] |
|                |   | Asynchronní motor                             | Detekce poruchy rotorových tyčí                          | 2015 [34] |
|                |   | Systém duálního motoru                        | Detekce poruch   | 2017 [35] |
|                |   | Větrná turbína                                | Detekce offset hodnot senzoru stoupání                   | 2016 [36] |
|                |   | Systém elektrického čerpadla                  | Detekce poruchy v motoru, aktuátorech a senzorech        | 2017 [37] |
| Markovův model | Vhodné využití při predikci s možností grafického znázornění. Aplikuje se v procesech, při kterých není stav systému viditelný pozorovatelem. | Točivý stroj                                  | Detekce poruch, snížení ceny údržby a zvýšení efektivity | 2017 [14] |
|                |   | Elektrický motor                              | Predikce poruch  | 2015 [38] |
|                |   | Ložiska                                       | Diagnostika poruch                                       | 2018 [39] |
|                |   | Výkonový transformátor                        | Predikce poruch  | 2019 [40] |
|                |   | Fotovoltaický invertor                        | Zefektivnění a zrychlení diagnostiky poruch              | 2017 [41] |

|                      |   |  |   |           |
|----------------------|---|--|---|-----------|
| Fault trees          | Disponuje vysokou přehledností díky grafickému znázornění. Využívá se pro lokalizaci poruch v technických soustavách.                                     | Nakládací stroj                          | Identifikace příčin poruchy nakládacího stroje            | 2018 [17] |
|                      |   | Skladovací a přepravní zařízení          | Diagnostika poruch  | 2017 [42] |
|                      |   | Nabíjecí zařízení pro elektrická vozidla | Lokalizace poruch   | 2018 [43] |
|                      |   | Elektromechanický aktuátor               | Lokalizace slabých částí a komponentů náchylných k poruše | 2015 [44] |
|                      |   | Větrná turbína                           | Diagnostika poruch hlavních komponentů převodovky         | 2019 [45] |
| Umělé neuronové sítě | Univerzální metoda s adaptivní povahou, která je vhodná pro nelineární systémy. Pro kvalitní diagnostiku však vyžaduje velké množství tréninkových vzorů. | Ložiska                                  | Detekce a klasifikace typu poruchy                        | 2019 [19] |
|                      |   | Plynová mikroturbína                     | Diagnostika poruch  | 2020 [46] |
|                      |   | Plovoucí větrná turbína                  | Zefektivnění diagnostiky poruch                           | 2020 [47] |
|                      |   | Vrtačka                                  | Diagnostika poruch na základě zvuku                       | 2017 [48] |
|                      |   | Hydraulický systém                       | Diagnostika poruch  | 2013 [49] |

|                        |  |  |   |           |
|------------------------|--|--|---|-----------|
| Support vector machine | Výpočtově nenáročná metoda, která je vhodná pro menší velikosti vzoru. Výborná pro modelování lineárních a nelineárních vztahů. Používá se především pro klasifikování poruch systému. | Generátor parní turbíny tepelné elektrárny | Diagnostika a klasifikace poruch                    | 2013 [22] |
|                        |  | Rotor                                      | Diagnostika a klasifikace typu poruchy              | 2019 [50] |
|                        |  | Lopatky větrné turbíny                     | Diagnostika a klasifikace typu poškození            | 2016 [51] |
|                        |  | Asynchronní motor                          | Diagnostika poruch                                  | 2018 [52] |
|                        |  | Ložiska                                    | Detekce a klasifikace poruchy                       | 2017 [53] |
| k-nearest neighbors    | Jednoduchá a velmi efektivní metoda klasifikování dat, kterou lze jednoduše znázornit i graficky.  | Asynchronní motor                          | Diagnostika poruch pomocí sledování napětí a proudu | 2016 [54] |
|                        |  | Výkonový transformátor                     | Diagnostika a klasifikace poruch                    | 2017 [55] |
|                        |  | Valivá ložiska                             | Diagnostika a klasifikace poruch                    | 2018 [56] |
|                        |  | Točivý stroj                               | Diagnostika a klasifikace poruch                    | 2018 [57] |
|                        |  | Výkonový olejový transformátor             | Zefektivnění diagnostiky poruch                     | 2016 [58] |



|                  |  |                                       |   |           |
|------------------|--|---------------------------------------|---|-----------|
| Bayesovské sítě  | Pravděpodobnostní metoda, která je reprezentována graficky. Dobrá pro modelování neurčitostí. Využívá se pro predikci i diagnostiku poruch.  | Transformátor                         | Diagnostika a klasifikace poruch                              | 2016 [28] |
|                  |  | Dveře kolejového vozidla              | Diagnostika a lokalizace poruch za účelem efektivnější údržby | 2019 [59] |
|                  |  | Rotor s variačním zatížením           | Diagnostika poruch  | 2013 [60] |
|                  |  | Systém mazání diesellového motoru     | Diagnostika a lokalizace poruch                               | 2020 [61] |
|                  |  | Elektrický asynchronní stroj          | Diagnostika a predikce poruch                                 | 2017 [62] |
| Expertní systémy | Vyznačuje se odděleným řídicím mechanismem od znalostí, které jsou reprezentovány ve formě pravidel, díky čemuž může poskytovat i řešení poruchy. Používá se pro zlepšení monitorování a údržby systému. | Vibrační systém mechanického zařízení | Diagnostika chyb a zlepšení monitorování mechanického stavu   | 2018 [31] |
|                  |  | Pneumatický regulační ventil          | Zlepšení přesnosti diagnostiky poruch                         | 2020 [63] |
|                  |  | Lodní diesellový motor                | Zefektivnění diagnostiky poruch                               | 2020 [64] |
|                  |  | Točivý stroj v tepelné elektrárně     | Diagnostika poruch  | 2020 [65] |
|                  |  | Zemědělské stroje                     | Zlepšení bezpečnosti a diagnostiky poruch                     | 2018 [66] |

|   |   |                        |  |              |
|---|---|------------------------|--|--------------|
| Adaptivní neuro fuzzy inferenční systém | Využívá výhod neurálních sítí a fuzzy logiky. Vykazuje vysokou přesnost v oblasti diagnostiky poruch. | Motor                  | Diagnostika poruch   | 2017<br>[33] |
|   |   | Asynchronní motor      | Diagnostika poruch na základě vibračního měření                            | 2017<br>[67] |
|   |   | Valivá ložiska         | Diagnostika poruch na základě vibračního signálu                           | 2014<br>[68] |
|   |   | Větrná turbína         | Diagnostika a klasifikace velikosti trhlin ozubených kol                   | 2014<br>[69] |
|   |   | Výkonový transformátor | Diagnostika poruch na základě rozpuštěných plynů v transformátorovém oleji | 2020<br>[70] |

*Tab. 1 – Shrnutí vlastností a aplikací nejpoužívanějších metod*


## 4 NEJPOUŽÍVANĚJŠÍ METODA V DIAGNOSTICE

Ve vědeckých pracích se nejčastěji objevovaly metody založené na neuronových sítích. V této části práce bude podrobně popsána metoda neuronových sítí a hybridní metoda ANFIS. Obě metody jsou hojně využívány v diagnostice technických soustav, což bude na závěr této kapitoly demonstrováno v podobě rešerše aplikace těchto metod v oblasti mechanických zařízení, elektrických strojů a pneumatických zařízení.

### 4.1 Neuronové sítě

Předlohou pro umělé neuronové sítě je lidský mozek a jeho struktura. Lidský mozek se skládá z husté sítě buněk, které jsou navzájem propojeny a nazývají se neurony. Princip fungování je takový, že neurony přijímají podněty na vstupu, zpracují je a výslednou informaci předají na výstup.

V umělých neuronových sítích se využívá umělý neuron, který je popsán matematickým modelem.



Obr. 7 – Matematický model umělého neuronu [3]

Na obr. 7 můžeme vidět umělý neuron, kde  $x(n)$  jsou vstupní signály, které jsou zesíleny či zeslabeny vahami  $w(n)$ . Vnitřní potenciál neuronu je pak vyčíslen vztahem (4.1-1) [3]:

$$\xi = \sum_{i=1}^n w_i x_i - h \quad (4.1-1)$$

Následný signál z neuronu přechází do aktivační přenosové funkce. Pokud budeme uvažovat nejjednodušší model (skoková přenosová funkce), pak bude aktivační přenosová funkce vypadat následovně [3]:

$$\sigma(\xi) = \begin{cases} 1 & \text{pokud } \xi \geq 0 \\ 0 & \text{pokud } \xi < 0 \end{cases} \quad (4.1-2)$$


Znamená to tedy, že pokud vnitřní potenciál neuronu bude větší nebo roven 0, pak výstupní signál bude 1, v opačném případě bude výstupní signál 0.

### 4.1.1 Přenosové funkce

Cílem přenosové funkce je převedení vstupní hodnoty na výstupní. Volba funkce pak závisí na typu umístění ve vrstvách a typu řešené úlohy.

Nejpoužívanějšími přenosovými funkcemi jsou:

- **Skoková přenosová funkce** – Nabývá pouze hodnot 0 nebo 1. Matematický popis této funkce je vztah (4.1-2) :




Obr. 8 – Skoková přenosová funkce [71]

- **Sigmoidální přenosová funkce** – V mínus nekonečnu se její hodnota blíží 0. V plus nekonečnu pak 1. Při hodnotě nula je rovna 0,5.

Matematický popis [3]:

$$\sigma(\xi) = \frac{1}{1+e^{-k\xi}} \quad (4.1-3)$$




Obr. 9 – Sigmoidální přenosová funkce [71]

### 4.1.2 Architektura sítě

Pro vytvoření neuronové sítě je důležité zvolení správné architektury. Existuje více typů, které se dělí dle způsobu propojení neuronů a jejich přenosových funkcí.

- **Perceptron** – Nejjednodušší architekturou sítě je perceptron. Jedná se o jeden neuron, jeho příklad je uveden na obr. 7. Jeho možnosti jsou značně omezené oproti ostatním architekturám. Využit jde pouze u množin, které jsou lineárně separovatelné. Pomocí perceptronu lze realizovat funkce jako AND, OR, NAND a NOR.
- **Vícevrstvá neuronová síť** – Jedná se o rozšíření architektury perceptronu, kde jsou neurony rozděleny do vrstev. Skládá se ze vstupní, skryté a výstupní vrstvy, přičemž skrytých vrstev může být i několik. Neurony jsou spojeny mezi vrstvami, ale nikoliv v jedné vrstvě. Příklad takové sítě je na obr. 10.



Obr. 10 – Vícevrstvá neuronová síť s jednou skrytou vrstvou [72]

- **Rekurentní neuronové sítě** – Jedná se o sítě obsahující vnitřní stav, který je reprezentován za pomoci spoje vedoucího zpět. Neuron tak počítá se vstupem a zároveň s předchozím výstupem. Tato síť je vhodná pro strojový překlad či generování textu.
- **Modulární neuronová síť** – Je vytvořena na základě zjištění, že mozek netvoří jedna velká síť neuronů, ale soubor malých sítí, které spolupracují nebo soutěží, aby vyřešily daný problém.

### 4.1.3 Strojové učení neuronové sítě

V neuronových sítích jsou zkušenosti uloženy v tzv. vahách. Cílem učení umělé neuronové sítě je tedy vyladit hodnoty vah tak, aby vytvořená síť dávala co nejpřesnější výsledky. Základní typy učících algoritmu jsou vypsány v kapitole 2.2.2.

Zmínit však můžeme ještě jeden učící algoritmus, a sice algoritmus Backpropagation. Jedná se o jeden z nejznámějších algoritmů učení, který se aplikuje ve vícevrstvých neuronových sítích a patří pod metodu učení s učitelem.

Principem této metody je z náhodně nastavených parametrů (vah) sítě, určit nejstrmější směr klesání (gradient) a postupně měnit parametry sítě, dokud se nezíská nejmenší chyba sítě. Jde tedy o nalezení lokálního minima.

Hodnota, o kterou se změní váhy, vychází z faktu, že pokud je parciální derivace chyby sítě kladná, tak chyba sítě roste spolu s růstem velikosti váhy. Proto se váha mění tak, že se k původní váze přičte negace této derivace.

Tato hodnota je vyjádřena vztahem (4.1-4) [73]:

$$\Delta w_{ji}(n) = \eta \delta_j x_{ji} + \alpha \Delta w_{ji}(n-1) \quad (4.1-4)$$

kde  $\alpha$  je tzv. momentum, které určuje velikost změn vah v daném směru a nabývá hodnot  $0 \leq \alpha < 1$ . Veličina  $\eta$  je pak parametr učení, který čím je větší, tím rychlejší je učení, ale na úkor kvality.

Veličina  $\delta_j$  je pak rovna

$$\delta_j = - \frac{\delta E}{\delta w_{ji}} \quad (4.1-5)$$

kde  $E$  je průměrná kvadratická chyba, která se vypočítá vztahem (4.1-6) [73]:

$$E = \frac{1}{2} \sum_k \epsilon \text{ výstupy} (t_k - o_k)^2 \quad (4.1-6)$$

kde  $t_k$  je cílová hodnota  $k$ , a  $o_k$  je výstup  $k$ , daný tréninkovým příkladem.

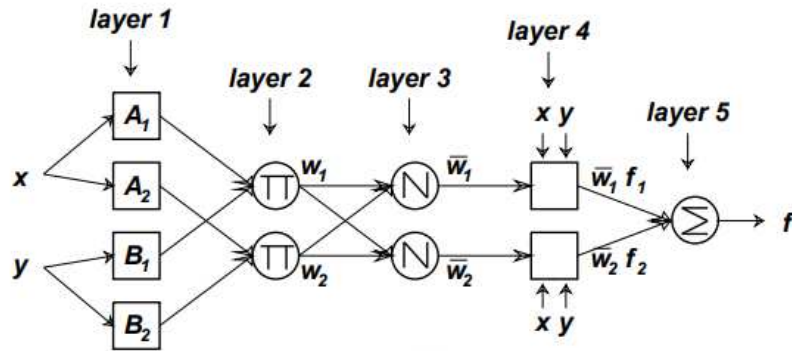
#### 4.1.4 Typy neuronových sítí

Neuronové sítě se dají rozdělit pomocí architektury sítě nebo stylu učení do několika typů.

- **Backpropagation neural network (BP)** – Jedná se o síť využívající algoritmus učení backpropagation (viz. kapitola 4.1.3).
- **Deep neural network (DNN)** – Tato síť se vyznačuje větším počtem vrstev mezi vstupní a výstupní vrstvou. Jde tedy v podstatě o více vrstvou neuronovou síť (viz. 4.1.2).
- **Convolutional neural network (CNN)** – Jedná se o podtřídu DNN. Její charakteristikou je, že využívá alespoň v jedné její vrstvě konvoluci místo násobení matic. Konvoluce je matematická operace na dvou funkcích, které produkují třetí funkci. Tato třetí funkce popisuje, jak se mění tvar první funkce za pomoci druhé funkce. Díky tomu je schopna samostatně optimalizovat své filtry skrze automatizované učení. Tím se stává nezávislá na předchozích znalostech či lidském zásahu při získávání funkcí.

## 4.2 Adaptivní neuro-fuzzy inferenční systém

ANFIS je jedním z modelů Neuro-Fuzzy systému. Popisovaný model struktury se nazývá type-3 ANFIS.



Obr. 11 – type-3 ANFIS [74]

Pro jednoduchost uvažujme fuzzy inferenční systém se dvěma vstupy  $x$  a  $y$  a jeden výstup  $z$ . Báze pravidel v tomto systému obsahuje dvě pravidla typu if-then.

Pravidla [74]:  
 IF  $x$  je  $A_1$  a  $y$  je  $B_1$ , THEN  $f_1 = p_1x + q_1y + r_1$   
 IF  $x$  je  $A_2$  a  $y$  je  $B_2$ , THEN  $f_2 = p_2x + q_2y + r_2$

Architektura ANFIS se skládá z 5 vrstev (obr 11).

**Vrstva 1 (vstupní vrstva)** – Každý uzel  $i$  v této vrstvě má funkci ve tvaru [74]:

$$O_i^1 = \mu A_i(x) \quad (4.2.1-1)$$

kde  $x$  je vstup uzlu  $i$ ,  $O_i^1$  je míra příslušnosti, kterou  $x$  naplňuje  $A_i$ , funkce  $\mu A_i$  se pak volí v intervalu  $\langle 0,1 \rangle$ . K tomu se využívá většinou Gaussova funkce nebo zvonová funkce [2-7].

**Vrstva 2 (pravidlová vrstva)** – Každý uzel v této vrstvě násobí vstupní signál a posílá ho na výstup [74]:

$$w_i = \mu A_i(x) \times \mu B_i(y), i = 1, 2 \quad (4.2.1-2)$$

Každý výstup reprezentuje sílu pravidla.

**Vrstva 3 (normalizační vrstva)** – Každý  $i$ -tý uzel vypočítá poměr síly  $i$ -tého pravidla k sumě sil všech pravidel [74]:

$$\bar{w}_i = \frac{w_i}{w_1 + w_2}, i = 1, 2 \quad (4.2.1-3)$$

kde  $w_i$  je síla vstupního pravidla a  $\bar{w}_i$  je normalizovaná síla.

**Vrstva 4 (defuzzifikační vrstva)** – Výstup této vrstvy je součin výstupu třetí vrstvy a funkce  $f_i$  z pravidlové báze [74]:

$$O_i^4 = \bar{w}_i f_i = \bar{w}_i (p_i x + q_i y + r_i) \quad (4.2.1-4)$$

**Vrstva 5 (sumační vrstva)** – Poslední vrstvu tvoří jeden uzel, který počítá celkový výstup jako sumaci všech vstupních signálů [74]:

$$O_1^5 = \sum_i \bar{w}_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i} \quad (4.2.1-5)$$

Parametry tohoto systému musí být vhodně nastaveny. Tyto parametry jsou dvojího typu: nelineární (ve vstupní vrstvě) a lineární (parametry v defuzzifikační vrstvě). Pro učení systému (nastavení parametrů) pak ANFIS využívá dvě učící metody (hybridní učící algoritmus): gradientní sestup (u parametrů vstupní vrstvy) a metodu nejmenších čtverců (u parametrů v defuzzifikační vrstvě). Učení systému skončí v případě, kdy byla dosažena požadovaná maximální chyba systému či bylo dosaženo zadaného počtu cyklů.

Gradientní sestup je optimalizační algoritmus, který se využívá v učícím algoritmu backpropagation (popsán v kapitole 4.1.3).

Metoda nejmenších čtverců se používá v případě, že neexistuje přesné řešení. Výsledné řešení je definováno jako minimální součet čtverců odchylek vůči každé rovnici. V podstatě jde o proložení souboru bodů přímkou.

## 4.3 Rešerše aplikace neuronových sítí a metody ANFIS

Tato část práce obsahuje popis aplikací v různých oblastech technických soustav. Zároveň jsou zde uvedeny tabulky, které shrnují použití a přesnost na daný problém vybranou metodou.

### 4.3.1 Využití při diagnostice mechanických zařízení

Diagnostika mechanických zařízení zpravidla pracuje na vstupu s vibračním signálem kritické polohy zařízení. Ten však mnohdy obsahuje velké množství šumu, který zkresluje výsledky analýzy. Často se diagnostika týká ložisek a ozubených kol.

Příkladem využití v této oblasti je práce z roku 2020 [75]. Zde byla metoda konvoluční neuronové sítě aplikována pro diagnostiku poruch ozubených kol v železniční převodovce. Aplikace detekovala pět stupňů stavů ozubeného kola: zdravé a 4 stupně trhlin (25-50-75-100 %). Metoda dosáhla přesnosti 96,04 % a přispěla ke zvýšení bezpečnosti a snížení ceny údržby.

Neuronové sítě využili autoři v práci [76] pro detekování a lokalizování ložiskového poškození vlivem vibrace, která je způsobena vysokými otáčkami turbíny. Při experimentu vznikl model neuronové sítě s 18 neurony ve skryté vrstvě. Tento model dosahoval přesnosti 82,79 % na reálných datech získaných ze senzorů.



V jiné práci [77] autoři použili ANFIS jako klasifikátor a lokalizátor poruchy v převodovce. Před vstupem vibračních dat aplikovali ještě techniku PCA (Principal Component Analysis) za účelem snížení dimenzionality těchto dat. Výstupní poruchy byly rozděleny do 8 tříd podle typu a místa. Model vykazoval přesnost až 96 %.

| Součástka / soustava | Účel  | Metoda                   | Přesnost  | Zdroj    |
|----------------------|---|--------------------------|-----------|----------|
| Ložiska              | Diagnostika a klasifikace poškození součástky   | Konvoluční neuronová síť | 99,41 %   | [19]     |
|                      | Diagnostika poškození součástky                 | ANFIS                    | 99,58 %   | [68]     |
|                      |   | Vícevrstvá neuronová síť | 82,79 %   | [[76]    |
| Ozubená kola         | Diagnostika a klasifikace trhlin                | Konvoluční neuronová síť | Přes 96 % | [75, 78] |
|                      | Diagnostika poškození součástky                 | Hluboká neuronová síť    | 97,31 %   | [79]     |
| Převodovka           | Diagnostika a lokalizace poškozeného komponentu | ANFIS                    | 96 %      | [77]     |
|                      | Diagnostika a klasifikace poškození součástky   | Konvoluční neuronová síť | 96,25 %   | [80, 81] |

Tab. 2 – a) Shrnutí úspěšných aplikací na danou součástku/soustavu

### 4.3.2 Využití při diagnostice elektrických a mechanických strojů

Příkladem použití je práce [82] ve které autoři aplikují vícevrstvou neuronovou síť spolu s učícím algoritmem backpropagation k diagnostice třífázového asynchronního motoru. Síť se měla naučit diagnostikovat 3 poruchové stavy, jeden za každou fází, přičemž její trénink proběhl na 75 tréninkových příkladech. Metoda zlepšila robustní výkon detekce poruchy statoru v přítomnosti variačního zatížení.

V práci [83] autoři provádí diagnostiku napájecího systému pomocí klasifikátoru založeného na neuronových sítích. Podobného cíle se snaží dosáhnout autoři v práci [84] z roku 2020, kde taktéž využívají umělé neuronové sítě jako klasifikátor chyb v napájecím systému.

Dalším příkladem aplikace neuronových sítí na asynchronní motor je vědecká práce [85]. V této práci autoři vytvořili model, který při diagnostice poruch bere v úvahu jak elektrické, tak mechanické příčiny závad. Výsledku bylo dosaženo na třech datových setech obsahujících vždy různý počet vstupních a výstupních hodnot a tréninkových vzorů. Sety se rozdělily na tréninkové a testové vzory, přičemž 75 % bylo vždy přiřazeno tréninkovým a 25 % testovacím vzorům, které však byly vybrány v náhodném pořadí. Pro každý datový set musel být vytvořený model modifikován, tj. byly změněny počty vstupních neuronů, počet skrytých vrstev apod.

| <b>Součástka / soustava</b> | <b>Účel</b>                                  | <b>Metoda</b>                 | <b>Přesnost</b> | <b>Zdroj</b> |
|-----------------------------|--|-------------------------------|-----------------|--------------|
| Větrná turbína              | Zefektivnění diagnostiky                     | Vícevrstvá neuronová síť      | Neuvedena       | [47, 86]     |
| Motor                       | Diagnostika a lokalizace poškození součástky | ANFIS                         | 87 %            | [33, 67]     |
|                             | Diagnostika a predikce poruch                | Vícevrstvá neuronová síť      | Neuvedena       | [87]         |
| Výkonový transformátor      | Diagnostika poruch                           | ANFIS                         | Neuvedena       | [70]         |
| Plynová turbína             | Diagnostika poruch                           | Backpropagation neuronová síť | Neuvedena       | [46]         |
| Vrtačka                     | Diagnostika poruch na základě zvuku          | Vícevrstvá neuronová síť      | 99,84 %         | [48]         |

*Tab. 3 – b) Shrnutí úspěšných aplikací na danou součástku/soustavu*

### 4.3.3 Využití při diagnostice pneumatických a hydraulických zařízení

Práce [88] z roku 2015 představuje aplikaci metody ANFIS v diagnostice technické soustavy, která je složená z pneumatického servomotoru, kontrolního ventilu a CPU (centrální výpočetní jednotka), sloužící ke kontrole pozice ventilu. Vytvořený model je schopen identifikovat celkem 19 různých poruch rozdělených do 4 skupin: porucha pneumatického servomotoru, porucha kontrolního ventilu, porucha CPU a obecná/externí porucha.

V další práci [89] autoři zkombinovali více-vrstvou neuronovou síť a algoritmus zobecněné prediktivní kontroly pro vytvoření prediktivního modelu pneumatického systému.

Autoři v práci [90] aplikovali vícevrstvou neuronovou síť pro diagnostiku poruch pneumatického regulačního ventilu. Síť měla 8 neuronů ve vstupní vrstvě a 3 ve výstupní. Při experimentu zjistili, že vhodný počet neuronů ve skryté vrstvě jsou 4, protože při dalším zvýšení se již efektivita sítě nezlepšila. Síť úspěšně diagnostikovala poruchy tlaku, blokování odvětrávání aktuátoru a únik skrze membránu regulačního ventilu.

| Součástka / soustava         | Účel   | Metoda                        | Přesnost  | Zdroj |
|------------------------------|--|-------------------------------|-----------|-------|
| Hydraulický systém           | Diagnostika a lokalizace poškození           | Backpropagation neuronová síť | 99,9 %    | [49]  |
| Pneumatický regulační ventil | Diagnostika a lokalizace poškozené součástky | ANFIS                         | Neuvedena | [88]  |
|                              |  | Vícevrstvá neuronová síť      | Neuvedena | [90]  |

Tab. 4 – c) Shrnutí úspěšných aplikací na danou součástku/soustavu

## 5 ZÁVĚR

Hlavním cílem této bakalářské práce bylo vytvoření přehledové rešerše používaných metod umělé inteligence v diagnostice technických soustav. První kapitola je věnována základnímu rozdělení a vlastnostem používaných metod umělé inteligence. Zvolené rozdělení nám rozděluje tyto metody na 4 skupiny, a to na model-based, data-driven AI a strojové učení, knowledge-based a hybridní metody. Vybrané metody jsou zde popsány z hlediska vlastností aplikace.

Zpracovaná tabulka v druhé kapitole shrnuje vlastnosti jednotlivých metod a uvádí konkrétní případy použití v technických soustavách.

Poslední kapitola obsahuje podrobný popis a využití nejpoužívanější metody umělé inteligence v diagnostice technických soustav. Na základě provedené rešerše považuji za nejpoužívanější metody umělou neuronovou síť a hybridní metodu „Adaptivní neuro fuzzy inferenční systém“, která je založena na neuronové síti. Díky mnoha typům (architektury sítě a učících algoritmů) se jedná o univerzální metody, které našly uplatnění v mnoha disciplínách. Jejich adaptivní povaha poskytuje vhodné vlastnosti pro použití na nelineární komplexní problémy. Použití těchto metod je rozděleno do tří oblastí: mechanická zařízení, elektrické a mechanické stroje a pneumatické a hydraulické systémy. V oblasti mechanických zařízení se jedná především o diagnostiku na základě vibračního signálu, přesnost dosahovala více než 96 % a to především v diagnostice ložisek, ozubených kol a převodovek. Oblast elektrických a mechanických strojů řeší diagnostiku motorů, turbín apod. Vzhledem k faktu, že se jedná o soustavy tvořené různými komponenty, často zde není uvedena přesnost diagnostiky. Poslední oblast pneumatických a hydraulických systémů pracuje s regulačními ventily, jejichž diagnostika taktéž zahrnuje více komponentů a mnohdy tedy není uvedena konkrétní přesnost. Všechny tyto aplikace jsou přehledně zpracovány v tabulkách 2, 3 a 4.

Metody umělé inteligence se využívají stále více, protože dokáží zpracovat velký objem dat mnohem rychleji než člověk. Jednotlivé metody se však liší s ohledem na vhodnost jejich využití. Například pravděpodobnostní metody jako Markovův model a Bayesovské sítě jsou vhodné pro predikci poruch, grafické metody jako fault trees, k-nearest neighbors nebo Support vector machine se zase používají pro klasifikaci poruch.

Systémy řízené umělou inteligencí jsou v dnešní době stále častěji využívány a jejich potenciál nadále roste. Při dalším vývoji bude vhodné se zaměřit na minimalizaci nevýhod jednotlivých metod, například u neuronových sítí na snížení jejich potřeby velkého množství tréninkových vzorů.

## 6 SEZNAM POUŽITÝCH ZDROJŮ

- [1] Lánský Milan. Systémová diagnostika. In: *Technická diagnostika a spolehlivost*. Česká společnost pro jakost. Praha, listopad 2011. Novotného lávka 5, 116 68 Praha 1, s. 3-22. ISBN 978-80-02-02352-4.
- [2] Sherwin D.J., Bossche A. (1993) Fault trees, event trees and success trees. In: *The Reliability, Availability and Productiveness of Systems*. Springer, Dordrecht. [https://doi.org/10.1007/978-94-011-1582-7\\_9](https://doi.org/10.1007/978-94-011-1582-7_9)
- [3] Blaha Milan. *Matematická biologie* [online]. 2014 [cit. 21.05.2021]. Dostupné z: <https://portal.matematickabiologie.cz/index.php?pg=analiza-a-hodnoceni-biologickych-dat--umela-inteligence>
- [4] Aplikace fuzzy množin pro určení technického stavu stroje. In: *Vše o průmyslu* [online]. 28.06.2017 [cit. 21.05.2021]. Dostupné z: <https://www.vseoprumsly.cz/udrzba-a-diagnostika/vibrodiagnostika/aplikace-fuzzy-mnoz-in-pro-urceni-technickeho-stavu-stroje.html>
- [5] X. Yin, C. Jiang and B. Li, "Fault diagnosis based on fault tree and Bayesian network for pure electric trucks," 2017 IEEE 2nd Information Technology, Networking, Electronic and Automation Control Conference (ITNEC), 2017, pp. 994-998, doi: 10.1109/ITNEC.2017.8284886.
- [6] S. Zhang, S. Zhang, B. Wang and T. G. Habetler, "Deep Learning Algorithms for Bearing Fault Diagnostics - A Review," 2019 IEEE 12th International Symposium on Diagnostics for Electrical Machines, Power Electronics and Drives (SDEMPED), 2019, pp. 257-263, doi: 10.1109/DEMPED.2019.8864915.
- [7] Sun Yuanyuan, Guo Lili and Wang Yongming, "Artificial intelligence and learning techniques in intelligent fault diagnosis," 2015 4th International Conference on Computer Science and Network Technology (ICCSNT), 2015, pp. 702-707, doi: 10.1109/ICCSNT.2015.7490841.
- [8] Dowdeswell, B., Sinha, R., & MacDonell, S.G. (2020) Finding faults: A scoping study of fault diagnostics for industrial cyber-physical systems, *Journal of Systems and Software* 168, pp.1-16. doi: 10.1016/j.jss.2020.110638.
- [9] A. Soualhi, B. Elyousfi, Y. Hawwari, K. Medjaher, G. Clerc, R. Hubert, F. Guillet, 2019 "PHM Survey: Implementation of Diagnostics Methods for Monitoring Industrial Systems, ", *International journal of prognostics and health management*. doi: 10.36001/ijphm.2019.v10i2.2733.
- [10] T. Wang, W. Xue and Q. Shao, "A Study based on a bank of Kalman Filters design for Gas Turbine Accessory Fault Detection," 2018 IEEE 3rd Advanced Information Technology, Electronic and Automation Control Conference (IAEAC), 2018, pp. 801-805, doi: 10.1109/IAEAC.2018.8577776.

- [11] Markovův řetězec. In: *Wikipedia* [online]. 18.01.2021 [cit. 21.05. 2021], Wikipedia. Dostupné z: [https://cs.wikipedia.org/wiki/Markov%C5%AFv\\_%C5%99et%C4%Bzec](https://cs.wikipedia.org/wiki/Markov%C5%AFv_%C5%99et%C4%Bzec)
- [12] Brundage, M. , Ademujimi, T. and Prabhu, V. (2017), A review of current machine learning techniques used in manufacturing diagnosis, APMS 2017 International Conference Advances in Production Management Systems (APMS 2017), Hamburg, -1, [online], [https://tsapps.nist.gov/publication/get\\_pdf.cfm?pub\\_id=923309](https://tsapps.nist.gov/publication/get_pdf.cfm?pub_id=923309)
- [13] Piotr Bilski and Jacek Wojciechowski. Artificial intelligence methods in diagnostics of analog systems. *International Journal of Applied Mathematics and Computer Science*, 24(2):271–282, 2014. (PDF) *Design of sensor and actuator multi model fault detection and isolation system using state space neural networks*. Dostupné z: [https://www.researchgate.net/publication/284195322\\_Design\\_of\\_sensor\\_and\\_actuator\\_multi\\_model\\_fault\\_detection\\_and\\_isolation\\_system\\_using\\_state\\_space\\_neural\\_networks](https://www.researchgate.net/publication/284195322_Design_of_sensor_and_actuator_multi_model_fault_detection_and_isolation_system_using_state_space_neural_networks)
- [14] N. A. Aditiya, M. R. Dharmawan, Z. Darojah and D. R. Sanggar, "Fault diagnosis system of rotating machines using Hidden Markov Model (HMM)," 2017 International Electronics Symposium on Knowledge Creation and Intelligent Computing (IES-KCIC), 2017, pp. 177-181, doi: 10.1109/KCIC.2017.8228583.
- [15] L. Wang, S. Li, O. Wei, M. Huang and J. Hu, "An Automated Fault Tree Generation Approach With Fault Configuration Based on Model Checking," in *IEEE Access*, vol. 6, pp. 46900-46914, 2018, doi: 10.1109/ACCESS.2018.2863696.
- [16] Schenkelberg Fred. Why and When to Use Fault Tree Analysis In: *accendoreliability* [online]. 2015 [cit. 21.05.2021]. Dostupné z: <https://accendoreliability.com/brief-introduction-fault-tree-analysis/>
- [17] N. Zhou, W. Li and J. Zhou, "Fault Diagnosis for Tray Loader Machine of Power Battery Based on Fault Tree Analysis," 2018 IEEE 3rd Advanced Information Technology, Electronic and Automation Control Conference (IAEAC), 2018, pp. 824-828, doi: 10.1109/IAEAC.2018.8577788.
- [18] J. MATTIOLI, P. PERICO and P. -O. ROBIC, "Improve Total Production Maintenance with Artificial Intelligence," 2020 Third International Conference on Artificial Intelligence for Industries (AI4I), 2020, pp. 56-59, doi: 10.1109/AI4I49448.2020.00019.
- [19] X. Li, S. Wang, W. Zhou, Q. Huang, B. Feng and L. Liu, "Research on Fault Diagnosis Algorithm Based on Convolutional Neural Network," 2019 11th International Conference on Intelligent Human-Machine Systems and Cybernetics (IHMSC), 2019, pp. 8-12, doi: 10.1109/IHMSC.2019.00010.
- [20] J. Xu and H. Yue, "Research on Fault Diagnosis Method of Power Grid Based on Artificial Intelligence," 2020 IEEE Conference on Telecommunications, Optics and Computer Science (TOCS), 2020, pp. 113-116, doi: 10.1109/TOCS50858.2020.9339711.

- [21] Support vector machines. In: *Wikipedia* [online]. 08.06.2020 [cit. 21.05. 2021], Wikipedia. Dostupné z: [https://cs.wikipedia.org/wiki/Support\\_vector\\_machines](https://cs.wikipedia.org/wiki/Support_vector_machines)
- [22] Lin Sang and T. Zhang, "Fault diagnosis of steam turbine generator unit based on support vector machine," *Proceedings of 2013 2nd International Conference on Measurement, Information and Control*, 2013, pp. 1264-1266, doi: 10.1109/MIC.2013.6758189.
- [23] H. b. Jaafar, N. b. Mukahar and D. A. Binti Ramli, "A methodology of nearest neighbor: Design and comparison of biometric image database," *2016 IEEE Student Conference on Research and Development (SCORED)*, 2016, pp. 1-6, doi: 10.1109/SCORED.2016.7810073.
- [24] Srivastava Tavish. Introduction to k-Nearest Neighbors: A powerful Machine Learning Algorithm (with implementation in Python & R) In: *analyticsvidhya* [online]. 2018 [cit. 21.05.2021]. Dostupné z: <https://www.analyticsvidhya.com/blog/2018/03/introduction-k-neighbours-algorithm-clustering/>
- [25] Okfalisa, I. Gazalba, Mustakim and N. G. I. Reza, "Comparative analysis of k-nearest neighbor and modified k-nearest neighbor algorithm for data classification," *2017 2nd International conferences on Information Technology, Information Systems and Electrical Engineering (ICITISEE)*, 2017, pp. 294-298, doi: 10.1109/ICITISEE.2017.8285514.
- [26] Z. Gao, C. Cecati and S. X. Ding, "A Survey of Fault Diagnosis and Fault-Tolerant Techniques—Part II: Fault Diagnosis With Knowledge-Based and Hybrid/Active Approaches," in *IEEE Transactions on Industrial Electronics*, vol. 62, no. 6, pp. 3768-3774, June 2015, doi: 10.1109/TIE.2015.2419013.
- [27] Soni Devin. Introduction to Bayesian Networks In: *analyticsvidhya* [online]. 2018 [cit. 21.05.2021]. Dostupné z: <https://towardsdatascience.com/introduction-to-bayesian-networks-81031eed94e>
- [28] Y. Cui, L. Naranpanawe and J. Seo, "Evolutionary Bayesian fusion for transformers fault detection," *2016 Australasian Universities Power Engineering Conference (AUPEC)*, 2016, pp. 1-6, doi: 10.1109/AUPEC.2016.7749299.
- [29] Celbová Iva. Úvod do problematiky expertních systémů. In: *Ikaros* [online]. 1999, ročník 3, číslo 8 [cit. 21.05.2021]. ISSN 1212-5075. Dostupné z: <http://ikaros.cz/node/10378>
- [30] 7. Expertní a neuronové systémy. In: *geologie.vsb* [online]. 2006 [cit. 21.05.2021]. Dostupné z: <http://geologie.vsb.cz/geoinformatika/>
- [31] Y. Wang, "Research on the Fault Diagnosis of Mechanical Equipment Vibration System Based on Expert System," *2018 International Conference on Sensing, Diagnostics, Prognostics, and Control (SDPC)*, 2018, pp. 636-641, doi: 10.1109/SDPC.2018.8665012.
- [32] Viharos, Zs. J.; Kis K. B.: Optimal Neuro-Fuzzy model configuration, *IEEE International Conference on Systems, Man, and Cybernetics (SMC 2016)*, October 9-12, Budapest, Hungary, ISBN 978-1-5090-1819-2, pp. 3640 – 3645.

- [33] C. Qing-Xie and W. Chun-Fu, "Research on engine fault diagnosis technology based on ANFIS," 2017 Chinese Automation Congress (CAC), 2017, pp. 278-281, doi: 10.1109/CAC.2017.8242777.
- [34] M. Rayyam, M. Zazi and Y. Hajji, "Detection of broken bars in induction motor using the Extended Kalman Filter (EKF)," 2015 Third World Conference on Complex Systems (WCCS), 2015, pp. 1-5, doi: 10.1109/ICoCS.2015.7483235.
- [35] G. Fumin, R. Xuemei, L. Zhijun and H. Cunwu, "Kalman filter based fault detection of dual motor systems," 2017 36th Chinese Control Conference (CCC), 2017, pp. 7133-7137, doi: 10.23919/ChiCC.2017.8028481.
- [36] D. Wu, C. Gao, Y. Zhai, Y. Shen and Z. Ji, "Fault diagnosis of pitch sensor bias for wind turbine based on the multi-innovation Kalman filter," 2016 35th Chinese Control Conference (CCC), 2016, pp. 6403-6407, doi: 10.1109/ChiCC.2016.7554363.
- [37] M. Rezaee, N. Sadeghzadeh-Nokhodberiz and J. Poshtan, "Kalman filter based sensor fault detection and identification in an electro-pump system," 2017 5th International Conference on Control, Instrumentation, and Automation (ICCIA), 2017, pp. 12-17, doi: 10.1109/ICCIAutom.2017.8258645.
- [38] A. Soualhi, G. Clerc and H. Razik, "Fault prognosis based on Hidden Markov Models," 2015 IEEE Workshop on Electrical Machines Design, Control and Diagnosis (WEMDCD), 2015, pp. 271-278, doi: 10.1109/WEMDCD.2015.7194540.
- [39] L. Cao, Y. Shen, T. Shan, Y. Xia, J. Wang and Z. Lin, "Bearing Fault Diagnosis Method Based on GMM and Coupled Hidden Markov Model," 2018 Prognostics and System Health Management Conference (PHM-Chongqing), 2018, pp. 932-936, doi: 10.1109/PHM-Chongqing.2018.00166.
- [40] J. Jiang, R. Chen, M. Chen, W. Wang and C. Zhang, "Dynamic Fault Prediction of Power Transformers Based on Hidden Markov Model of Dissolved Gases Analysis," in IEEE Transactions on Power Delivery, vol. 34, no. 4, pp. 1393-1400, Aug. 2019, doi: 10.1109/TPWRD.2019.2900543.
- [41] H. Zheng, R. Wang, Y. Wang and W. Zhu, "Fault diagnosis of photovoltaic inverters using hidden Markov model," 2017 36th Chinese Control Conference (CCC), 2017, pp. 7290-7295, doi: 10.23919/ChiCC.2017.8028508.
- [42] C. Li, C. Zhu, K. Zhang and H. Wei, "Fault diagnosis algorithm for storage and transportation equipment based on fault tree," 2017 29th Chinese Control And Decision Conference (CCDC), 2017, pp. 4692-4697, doi: 10.1109/CCDC.2017.7979326.
- [43] D. Gao, J. Hou, K. Liang and Q. Yang, "Fault Diagnosis System for Electric Vehicle Charging Devices Based on Fault Tree Analysis," 2018 37th Chinese Control Conference (CCC), 2018, pp. 5055-5059, doi: 10.23919/ChiCC.2018.8482691.



- [44] C. Yuyan, W. Jian, X. Rong and W. Xinmin, "Fault tree analysis of electro-mechanical actuators," 2015 34th Chinese Control Conference (CCC), 2015, pp. 6392-6396, doi: 10.1109/ChiCC.2015.7260646.
- [45] H. Zhu and X. Fu, "Fault Analysis of Wind Turbine Gearbox Based on Vague Set and Fault Tree," 2019 6th International Conference on Systems and Informatics (ICSAI), 2019, pp. 218-222, doi: 10.1109/ICSAI48974.2019.9010177.
- [46] Y. Liu, J. Wang and Y. Shen, "Research on Verification of Sensor Fault Diagnosis Based on BP Neural Network," 2020 11th International Conference on Prognostics and System Health Management (PHM-2020 Jinan), 2020, pp. 456-460, doi: 10.1109/PHM-Jinan48558.2020.00088.
- [47] H. Hui, L. Xiu-wen and B. Jing-yu, "The Application of Artificial Intelligence Technology in the Fault Diagnosis of Floating Wind Turbine Generator," 2020 5th International Conference on Electromechanical Control Technology and Transportation (ICECTT), 2020, pp. 305-307, doi: 10.1109/ICECTT50890.2020.00074.
- [48] C. Vununu, K. Kwon, E. Lee, K. Moon and S. Lee, "Automatic Fault Diagnosis of Drills Using Artificial Neural Networks," 2017 16th IEEE International Conference on Machine Learning and Applications (ICMLA), 2017, pp. 992-995, doi: 10.1109/ICMLA.2017.00-23.
- [49] Zhang Yinshuo, Xia Jun and Li Lei, "Fault diagnosis of hydraulic system based on improved BP neural network technology," Proceedings of 2013 2nd International Conference on Measurement, Information and Control, 2013, pp. 137-140, doi: 10.1109/MIC.2013.6757933.
- [50] Q. Yang, D. Guo, W. Yao, J. Cai and C. Mei, "Support Vector Machines based Rotor Fault Diagnosis with Improved Particle Swarm optimization," 2019 Chinese Automation Congress (CAC), 2019, pp. 4321-4324, doi: 10.1109/CAC48633.2019.8996884.
- [51] S. Qiang, H. Lin and Z. Yu, "Online faults diagnosis of wind turbine blades based on support vector machines," 2016 3rd International Conference on Systems and Informatics (ICSAI), 2016, pp. 247-250, doi: 10.1109/ICSAI.2016.7810962.
- [52] H. Guo and M. Liu, "Induction motor faults diagnosis using support vector machine to the motor current signature," 2018 IEEE Industrial Cyber-Physical Systems (ICPS), 2018, pp. 417-421, doi: 10.1109/ICPHYS.2018.8390701.
- [53] J. S. L. Senanayaka, S. T. Kandukuri, Huynh Van Khang and K. G. Robbersmyr, "Early detection and classification of bearing faults using support vector machine algorithm," 2017 IEEE Workshop on Electrical Machines Design, Control and Diagnosis (WEMDCD), 2017, pp. 250-255, doi: 10.1109/WEMDCD.2017.7947755.
- [54] S. Samanta, J. N. Bera and G. Sarkar, "KNN based fault diagnosis system for induction motor," 2016 2nd International Conference on Control, Instrumentation, Energy & Communication (CIEC), 2016, pp. 304-308, doi: 10.1109/CIEC.2016.7513791.

- [55] W. Mo, T. Kari, H. Wang, L. Luan and W. Gao, "Fault diagnosis of power transformer using feature selection techniques and KNN," 2017 3rd IEEE International Conference on Computer and Communications (ICCC), 2017, pp. 2827-2831, doi: 10.1109/CompComm.2017.8323048.
- [56] A. Sharma, R. Jigyasu, L. Mathew and S. Chatterji, "Bearing Fault Diagnosis Using Weighted K-Nearest Neighbor," 2018 2nd International Conference on Trends in Electronics and Informatics (ICOEI), 2018, pp. 1132-1137, doi: 10.1109/ICOEI.2018.8553800.
- [57] Y. Yinghua, S. Guoqiang and S. Xiang, "Fault monitoring and classification of rotating machine based on PCA and KNN," 2018 Chinese Control And Decision Conference (CCDC), 2018, pp. 1795-1800, doi: 10.1109/CCDC.2018.8407418.
- [58] F. Yu, J. Liu and D. Liu, "An approach for fault diagnosis based on an improved k-nearest neighbor algorithm," 2016 35th Chinese Control Conference (CCC), 2016, pp. 6521-6525, doi: 10.1109/ChiCC.2016.7554383.
- [59] R. Chen, S. Zhu, F. Hao, B. Zhu, Z. Zhao and Y. Xu, "Railway Vehicle Door Fault Diagnosis Method with Bayesian Network," 2019 4th International Conference on Control and Robotics Engineering (ICCRE), 2019, pp. 70-74, doi: 10.1109/ICCRE.2019.8724211.
- [60] Z. Cai, S. Sun, S. Si and W. Zhang, "Rotor fault diagnosis for machinery fault simulator under varied loads," 2013 Proceedings Annual Reliability and Maintainability Symposium (RAMS), 2013, pp. 1-6, doi: 10.1109/RAMS.2013.6517706.
- [61] D. Ren, H. Zeng, X. Wang, S. Pang and J. Wang, "Fault Diagnosis of Diesel Engine Lubrication System Based on Bayesian Network," 2020 6th International Conference on Control, Automation and Robotics (ICCAR), 2020, pp. 423-429, doi: 10.1109/ICCAR49639.2020.9108107.
- [62] A. Lakehal, A. Ramdane and F. Tachi, "A Bayesian network tool for improving the fault prediction of electrical asynchronous machine," 2017 IEEE 58th International Scientific Conference on Power and Electrical Engineering of Riga Technical University (RTUCON), 2017, pp. 1-5, doi: 10.1109/RTUCON.2017.8124745.
- [63] D. Zhang, J. Hao, L. Chen and L. Zhou, "Fault Diagnosis Approach for Pneumatic Control Valves Based on Modified Expert System," 2020 19th International Symposium on Distributed Computing and Applications for Business Engineering and Science (DCABES), 2020, pp. 104-107, doi: 10.1109/DCABES50732.2020.00035.
- [64] X. Xu, X. Yan, C. Sheng, C. Yuan, D. Xu and J. Yang, "A Belief Rule-Based Expert System for Fault Diagnosis of Marine Diesel Engines," in IEEE Transactions on Systems, Man, and Cybernetics: Systems, vol. 50, no. 2, pp. 656-672, Feb. 2020, doi: 10.1109/TSMC.2017.2759026.

- [65] X. He et al., "Recommendation and Election Expert System for Rotating Machinery Fault Diagnosis Based on the Combination of Rules and Examples," 2020 IEEE International Conference on Energy Internet (ICEI), 2020, pp. 34-39, doi: 10.1109/ICEI49372.2020.00015.
- [66] Z. Dong, J. Zhao, J. Duan, M. Wang and H. Wang, "Research on Agricultural Machinery Fault Diagnosis System Based on Expert System," 2018 2nd IEEE Advanced Information Management, Communicates, Electronic and Automation Control Conference (IMCEC), 2018, pp. 2057-2060, doi: 10.1109/IMCEC.2018.8469579.
- [67] M. Moghadasian, S. M. Shakouhi and S. S. Moosavi, "Induction motor fault diagnosis using ANFIS based on vibration signal spectrum analysis," 2017 3rd International Conference on Frontiers of Signal Processing (ICFSP), 2017, pp. 105-108, doi: 10.1109/ICFSP.2017.8097151.
- [68] J. Zhang, W. Ma and L. Ma, "A fault diagnosis method based on ANFIS and bearing fault diagnosis," 2014 International Conference on Information Science, Electronics and Electrical Engineering, 2014, pp. 1274-1278, doi: 10.1109/InfoSEEE.2014.6947876.
- [69] K. Bae, B. Choi, J. Park and B. Kim, "A study on crack fault diagnosis of wind turbine simulation system," 2014 10th International Conference on Reliability, Maintainability and Safety (ICRMS), 2014, pp. 53-57, doi: 10.1109/ICRMS.2014.7107135.
- [70] A. I. Koldaev, A. A. Evdokimov and B. M. Shebzukhova, "An Approach to Neuro-Fuzzy Monitoring of Power Transformers," 2020 International Multi-Conference on Industrial Engineering and Modern Technologies (FarEastCon), 2020, pp. 1-5, doi: 10.1109/FarEastCon50210.2020.9271394.
- [71] Umělá neuronová síť. In: *Wikipedia* [online]. 28.07.2020 [cit. 21.05. 2021], Wikipedia. Dostupné z: [https://cs.wikipedia.org/wiki/Um%C4%9Bl%C3%A1\\_neuronov%C3%A1\\_s%C3%AD%C5%A5](https://cs.wikipedia.org/wiki/Um%C4%9Bl%C3%A1_neuronov%C3%A1_s%C3%AD%C5%A5)
- [72] Deep learning. In: *Simple Wikipedia* [online]. 28.10.2018 [cit. 21.05. 2021], Wikipedia. Dostupné z: [https://simple.wikipedia.org/wiki/Deep\\_learning](https://simple.wikipedia.org/wiki/Deep_learning)
- [73] MITCHELL, Tom M. *Machine learning*. 1. ed. New York : McGraw-Hill, Inc., March 1997. 432 p. ISBN 0070428077
- [74] J. -. R. Jang, "ANFIS: adaptive-network-based fuzzy inference system," in *IEEE Transactions on Systems, Man, and Cybernetics*, vol. 23, no. 3, pp. 665-685, May-June 1993, doi: 10.1109/21.256541.
- [75] F. Karpat, A. E. Dirik, O. Doğan, O. C. Kalay, B. Korçuklu and C. Yüce, "A Novel AI-Based Method for Spur Gear Early Fault Diagnosis in Railway Gearboxes," 2020 Innovations in Intelligent Systems and Applications Conference (ASYU), 2020, pp. 1-6, doi: 10.1109/ASYU50717.2020.9259819.

- [76] M. Ben Rahmoune, A. Hafaifa, A. Kouzou, M. Guemana and S. Abudura, "Control and diagnostic of vibration in gas turbine system using neural network approach," 2016 8th International Conference on Modelling, Identification and Control (ICMIC), 2016, pp. 573-577, doi: 10.1109/ICMIC.2016.7804177.
- [77] I. Attoui, A. Boudiaf, N. Fergani, B. Oudjani, N. Boutasseta and A. Deliou, "Vibration-based gearbox fault diagnosis by DWPT and PCA approaches and an adaptive neuro-fuzzy inference system," 2015 16th International Conference on Sciences and Techniques of Automatic Control and Computer Engineering (STA), 2015, pp. 234-239, doi: 10.1109/STA.2015.7505177.
- [78] G. Cirrincione, R. R. Kumar, A. Mohammadi, S. H. Kia, P. Barbiero and J. Ferretti, "Shallow Versus Deep Neural Networks in Gear Fault Diagnosis," in IEEE Transactions on Energy Conversion, vol. 35, no. 3, pp. 1338-1347, Sept. 2020, doi: 10.1109/TEC.2020.2978155.
- [79] M. Heydarzadeh, S. H. Kia, M. Nourani, H. Henao and G. Capolino, "Gear fault diagnosis using discrete wavelet transform and deep neural networks," IECON 2016 - 42nd Annual Conference of the IEEE Industrial Electronics Society, 2016, pp. 1494-1500, doi: 10.1109/IECON.2016.7793549.
- [80] Z. Cheng, N. Hu, J. Chen, M. Gao and Q. Zhu, "Fault Detection of Planetary Gearboxes Based on Deep Convolutional Neural Network," 2019 Prognostics and System Health Management Conference (PHM-Qingdao), 2019, pp. 1-5, doi: 10.1109/PHM-Qingdao46334.2019.8942831.
- [81] J. He, P. Wu, J. Gao, X. Zhang and S. Lou, "Wind Turbine Gearbox Fault Detection based on Dilated Convolutional Neural Networks," 2020 7th International Conference on Information, Cybernetics, and Computational Social Systems (ICCSS), 2020, pp. 517-521, doi: 10.1109/ICCSS52145.2020.9336913.
- [82] N. Lashkari, H. F. Azgomi, J. Poshtan and M. Poshtan, "Asynchronous motors fault detection using ANN and fuzzy logic methods," 2016 IEEE Energy Conversion Congress and Exposition (ECCE), 2016, pp. 1-5, doi: 10.1109/ECCE.2016.7854890.
- [83] K. Xu, "Fault Diagnosis Method of Power System Based on Neural Network," 2018 International Conference on Virtual Reality and Intelligent Systems (ICVRIS), 2018, pp. 172-175, doi: 10.1109/ICVRIS.2018.00049.
- [84] K. Moloi and A. A. Yusuff, "A Wavelet-Neural Network-Based Technique for Fault Diagnostics in Power System," 2020 7th International Conference on Soft Computing & Machine Intelligence (ISCMI), 2020, pp. 131-135, doi: 10.1109/ISCMI51676.2020.9311601.
- [85] S. Dmitry, S. Maxim and Z. Dmitry, "Identification of the Asynchronous Electric Motor Defects Based on Neural Networks," 2017 IEEE 11th International Conference on Application of Information and Communication Technologies (AICT), 2017, pp. 1-4, doi: 10.1109/AICT.2017.8686992.

- [86] M. Nithya, S. Nagarajan and P. Navaseelan, "Fault detection of wind turbine system using neural networks," 2017 IEEE Technological Innovations in ICT for Agriculture and Rural Development (TIAR), 2017, pp. 103-108, doi: 10.1109/TIAR.2017.8273694.
- [87] R. A. Patel and B. R. Bhalja, "Induction motor rotor fault detection using Artificial Neural Network," 2015 International Conference on Energy Systems and Applications, 2015, pp. 45-50, doi: 10.1109/ICESA.2015.7503311.
- [88] Y. A. Korablev, N. A. Logutova and M. Y. Shestopalov, "Neural network application to diagnostics of pneumatic servo-motor actuated control valve," 2015 XVIII International Conference on Soft Computing and Measurements (SCM), 2015, pp. 42-46, doi: 10.1109/SCM.2015.7190406.
- [89] Q. Song, F. Liu and R. D. Findlay, "Generalized Predictive Control for a Pneumatic System Based on an Optimized ARMAX Model with an Artificial Neural Network," 2006 International Conference on Computational Intelligence for Modelling Control and Automation and International Conference on Intelligent Agents Web Technologies and International Commerce (CIMCA'06), 2006, pp. 223-223, doi: 10.1109/CIMCA.2006.111.
- [90] M. Karpenko and N. Sepehri, "A neural network based fault detection and identification scheme for pneumatic process control valves," 2001 IEEE International Conference on Systems, Man and Cybernetics. e-Systems and e-Man for Cybernetics in Cyberspace (Cat.No.01CH37236), 2001, pp. 93-98 vol.1, doi: 10.1109/ICSMC.2001.969794.

## 7 SEZNAM OBRÁZKŮ A TABULEK

### 7.1 Seznam obrázků

|  |    |
|--|----|
| Obr. 1 – Jednoduchý diskretní Markovův řetězec se dvěma stavy..... | 13 |
| Obr. 2 – Ukázkový diagram analýzy fault trees.....                 | 14 |
| Obr. 3 – Příklad lineárně separovaného prostoru příznaků.....      | 17 |
| Obr. 4 – Jednoduchá ukázka metody k-nearest neighbors.....         | 18 |
| Obr. 5 – Příklad jednoduché Bayesovské sítě.....                   | 19 |
| Obr. 6 – Schéma expertního systému.....                            | 20 |
| Obr. 7 – Matematický model umělého neuronu.....                    | 27 |
| Obr. 8 – Skoková přenosová funkce.....                             | 28 |
| Obr. 9 – Sigmoidální přenosová funkce.....                         | 28 |
| Obr. 10 – Vícevrstvá neuronová síť s jednou skrytou vrstvou.....   | 29 |
| Obr. 11 – type-3 ANFIS.....  | 31 |

### 7.2 Seznam tabulek

|   |       |
|---|-------|
| Tab. 1 – Shrnutí vlastností a aplikací nejpoužívanějších metod.....     | 22-26 |
| Tab. 2 – a) Shrnutí úspěšných aplikací na danou součástku/soustavu..... | 33    |
| Tab. 3 – b) Shrnutí úspěšných aplikací na danou součástku/soustavu..... | 34    |
| Tab. 4 – c) Shrnutí úspěšných aplikací na danou součástku/soustavu..... | 35    |