



# VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

## FAKULTA STROJNÍHO INŽENÝRSTVÍ

FACULTY OF MECHANICAL ENGINEERING

## ÚSTAV VÝROBNÍCH STROJŮ, SYSTÉMŮ A ROBOTIKY

INSTITUTE OF PRODUCTION MACHINES, SYSTEMS AND ROBOTICS

## UMĚLÁ INTELIGENCE V PRŮMYSLU 4.0

ARTIFICIAL INTELLIGENCE AND INDUSTRY 4.0

### BAKALÁŘSKÁ PRÁCE

BACHELOR'S THESIS

### AUTOR PRÁCE

AUTHOR

Radim Hirsch

### VEDOUCÍ PRÁCE

SUPERVISOR

Ing. Jiří Kovář, Ph.D.

BRNO 2020



# Zadání bakalářské práce

Ústav: Ústav výrobních strojů, systémů a robotiky  
Student: **Radim Hirsch**  
Studijní program: Strojírenství  
Studijní obor: Stavba strojů a zařízení  
Vedoucí práce: **Ing. Jiří Kovář, Ph.D.**  
Akademický rok: 2019/20

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:

## Umělá inteligence v průmyslu 4.0

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

Cílem práce je rešeršní zpracování problematiky použití metod umělé inteligence v kontextu Průmyslu 4.0.

### **Cíle bakalářské práce:**

Zpracujte podrobnou rešerši použití metod umělé inteligence v kontextu Průmyslu 4.0.

Vyberte jednu z používaných metod umělé inteligence a popište ji.

Vyhodnoťte vybranou metodu.

### **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 2019/20

V Brně, dne

L. S.

---

---

doc. Ing. Petr Blecha, Ph.D.  
ředitel ústavu

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

## **ABSTRAKT**

Cílem této práce je poskytnout přehled aplikací metod umělé inteligence v kontextu průmyslu 4.0. První kapitola je věnována definici konceptu průmyslu 4.0, předchozímu vývoji průmyslu a zařazení vědního oboru umělé inteligence do tohoto konceptu. Druhá kapitola je zaměřena na řešení aplikací metod umělé inteligence v oblasti obrábění, výrobního průmyslu, automatizace a energetiky. Závěr práce je věnován zhodnocení metod, jejich výhod a úskalí z pohledu jednotlivých praktických aplikací a zmiňuje možné směry budoucího vývoje.

## **ABSTRACT**

The aim of this work is to provide an overview of the application of artificial intelligence methods in the context of Industry 4.0. The first chapter defines the concept of industry 4.0, previous development of the industry and inclusion of the scientific field of artificial intelligence in this concept. The second chapter is focused on the applications of artificial intelligence methods in the field of machining, manufacturing industry, automation and energetics. The work concludes with evaluation of methods, their advantages and disadvantages from the point of view of individual practical applications and mentions possible directions of future development.

## **KLÍČOVÁ SLOVA**

Umělá inteligence, Průmysl 4.0, Metody strojového učení, Umělé neuronové sítě, Metody obrábění, Automatizace, Průmyslová výroba, Energetika

## **KEYWORDS**

Artificial Intelligence, Industry 4.0, Machine Learning Methods, Artificial Neural Networks, Machining Methods, Automation, Industrial Manufacturing, Energetics



## **BIBLIOGRAFICKÁ CITACE**

HIRSCH, Radim. Umělá inteligence v průmyslu 4.0. Brno, 2020. Dostupné také z: <https://www.vutbr.cz/studenti/zav-prace/detail/124627>. Bakalářská práce. Vysoké učení technické v Brně, Fakulta strojního inženýrství, Ústav výrobních strojů, systémů a robotiky. Vedoucí práce Jiří Kovář.





## **PODĚKOVÁNÍ**

Tímto bych rád poděkoval svému vedoucímu bakalářské práce Ing. Jiřímu Kovářovi, Ph.D. za jeho odborné vedení, ochotu, čas, a hlavně trpělivost při vytváření této bakalářské práce. Děkuji také mé rodině za podporu během celého studia.



## **ČESTNÉ PROHLÁŠENÍ**

Prohlašuji, že tato práce je mým původním dílem, zpracoval jsem ji samostatně pod vedením Ing. Jiřího Kováře, Ph.D. a s použitím literatury uvedené v seznamu.

V Brně dne 25. 6. 2020

.....

Radim Hirsch



# OBSAH

<b>1</b>	<b>ÚVOD</b> .....	<b>15</b>
<b>2</b>	<b>ANALÝZA UMĚLÉ INTELIGENCE V PRŮMYSLU 4.0</b> .....	<b>17</b>
2.1.	Historie průmyslu .....	18
2.2.	Definice umělé inteligence v kontextu průmyslu 4.0.....	19
<b>3</b>	<b>REŠERŠNÍ STUDIE APLIKACE METOD UMĚLÉ INTELIGENCE</b> .....	<b>20</b>
3.1.	Konvenční metody obrábění .....	20
3.1.1.	Frézování .....	20
3.1.2.	Soustružení.....	21
3.1.3.	Broušení.....	21
3.1.4.	Vrtání .....	21
3.1.5.	Vyvtávání .....	22
3.2.	Nekonvenční metody obrábění .....	22
3.2.1.	Řezání laserem .....	22
3.2.2.	Řezání vodním paprskem.....	22
3.2.3.	Elektroerozivní obrábění.....	23
3.2.4.	Elektrochemické obrábění .....	23
3.3.	Stavba obráběcího stroje .....	23
3.4.	Výběr vhodného materiálu pro výrobu produktu .....	23
3.5.	Automatizační řízení.....	28
3.5.1.	Zjednodušení procesu .....	28
3.5.2.	Diagnostika poruch .....	29
3.5.3.	Elektronické řízení.....	29
3.5.4.	Elektrická zařízení .....	30
3.5.5.	Každodenní provoz.....	30
3.6.	Průmyslová výroba .....	30
3.6.1.	Metalurgické průmyslové odvětví .....	31
3.7.	Energetika .....	33
3.7.1.	Energetické řízení .....	34
3.7.2.	Reakce na poptávku .....	36
3.7.3.	Trh s elektřinou.....	37
<b>4</b>	<b>ZHODNOCENÍ A DISKUZE</b> .....	<b>38</b>
<b>5</b>	<b>ZÁVĚR</b> .....	<b>43</b>
<b>6</b>	<b>SEZNAM POUŽITÝCH ZDROJŮ</b> .....	<b>44</b>
<b>7</b>	<b>SEZNAM ZKRATEK, SYMBOLŮ, OBRÁZKŮ A TABULEK</b> .....	<b>55</b>
7.1.	Seznam zkratk .....	55
7.2.	Seznam obrázků.....	56
7.3.	Seznam tabulek .....	56



# 1 ÚVOD

V současné době, kdy je již v průmyslu zřetelný nástup trendů tzv. Smart Manufacturing a Smart Factory, za kterými se skrývá postupná aplikace principů konceptu Průmysl 4.0, se hlavním nástrojem této tzv. průmyslové revoluce, mimo jiných, stává praktická aplikace metod umělé inteligence na jednotlivé operace, ve všech odvětvích průmyslu.

Zavádění těchto nových nástrojů však není pouze technologický posun, jako jsme již zažili při 3. průmyslové revoluci, kdy se na scénu dostaly výpočetní technologie a první prvky automatizace, v tomto případě se jedná o postupné systematické zavádění nejnovějších technologií, které mají za cíl zvýšit efektivitu operací, snížit výrobní náklady a především pro zaměstnance velmi podstatné snížení pracovní námahy a v konkrétních případech nahrazení lidské práce, při níž zaměstnanci vykonávají jednu a tu samou monotónní činnost celý den, roboty, kteří ji zvládnou vykonávat přesněji a rychleji, než jejich lidské kolegové.

Cílem této práce je poskytnout čtenáři přehledný souhrn různorodých použití metod umělé inteligence v praktických aplikacích. Samotné téma umělé inteligence je totiž v současné době velmi složité a nepřehledné a společně s obrovskou množinou odborných studií, které se tomuto tématu věnují, vytváří neznalému čtenáři velkou bariéru porozumění, protože obrovské množství studií je vedeno spíše v obecné rovině a dopátrání se prací, ve kterých se autoři zaměřují na použití konkrétní metody umělé inteligence na konkrétní reálnou činnost je velice pracné a časově náročné.






## 2 ANALÝZA UMĚLÉ INTELIGENCE V PRŮMYSLU 4.0

V dnešní době si již lidé zvykli na každodenní používání výpočetní techniky a jiných elektronických pomůcek, které jim usnadňují ať už pracovní nebo osobní život. Tento trend se již mnoho let objevuje také v průmyslu, kde postupně dochází k zavádění digitálních technologií ve všech odvětvích, od používání CAD programů při konstrukci produktu, přes využití informačních systémů v ekonomické a obchodní sféře až po zavádění automatizovaných výrobních pracovišť, kde se při použití kolaborativních robotů přímo střetává práce lidí a strojů. Nicméně všechny tyto prvky modernizace se zavádějí bez zjevné vize propojení jednotlivých technologií v uzavřený celek. S touto myšlenkou však přichází koncept Průmysl 4.0, který se dostal do širšího povědomí veřejnosti v roce 2011, kdy asociace německých zástupců obchodní, politické a akademické sféry podpořila tuto myšlenku jako vhodný přístup k posílení konkurenceschopnosti produkce německého průmyslu. Tento koncept transformuje výrobu ze samostatných automatizovaných jednotek na plně integrované automatizované a průběžně optimalizované výrobní systémy, které jsou spolu se systémy logistiky zastoupeny ve formě kyberneticko-fyzických systémů – CPS (Cyber-Physical Systems). CPS intenzivně využívají globálně dostupné informační a komunikační sítě pro rozsáhle automatizovanou výměnu informací a propojují výrobní a obchodní procesy v jeden uzavřený celek. [1]

Koncept Průmysl 4.0 je založen na technologiích, jako je vertikální a horizontální integrace výrobních systémů, Internet věcí (Internet of Things – IoT), kybernetická bezpečnost, Cloud, který zahrnuje ukládání dat do vzdálených datových uložišť a jejich zpracování pomocí cloudových výpočtů, Analýza velkých dat (Big Data), Simulace, Aditivní výroba (3D tisk), Rozšířená realita a Robotika, přehled těchto metod zobrazuje Obr.1). Všechny tyto technologie srovnané do uceleného konceptu Průmyslu 4.0 mají za cíl zvýšení produktivity práce (podle studie National Academy of Science and Engineering, slibovaný nárůst až od 32 %), značné usnadnění tvorby produktu zákazníkovi na míru, snížení závislosti na lidské práci a výhodu pro zaměstnance, neboť nebudou muset vykonávat fyzicky těžkou a rutinní práci. Tímto způsobem je také pozitivně ovlivněno prodloužení doby, po kterou budou lidé schopni vykonávat svoji práci a také benefit v podobě pracovní flexibility. V globálním měřítku veškeré změny přispějí k řešení globálních problémů, jako je nedostatek surovin, energetická účinnost či demografické změny. [2]



Obr. 1) Technologie průmyslu 4.0 [2]

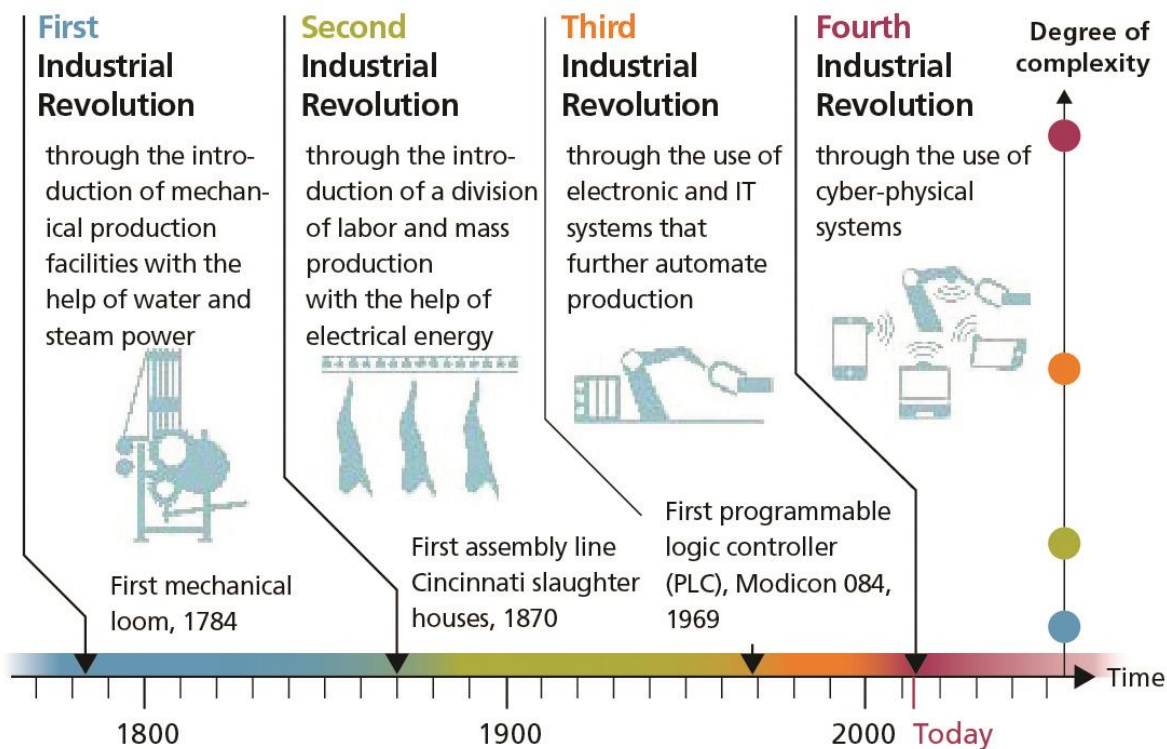
## 2.1 Historie průmyslu

Historie průmyslu se dělí na jednotlivé fáze probíhajících změn, nazývaných průmyslové revoluce, první tři revoluce již proběhly a čtvrtou revoluci zažíváme v současné době, jak je znázorněno v Obr.2).

První průmyslová revoluce započala na konci 18. století, přesněji se počátek datuje do roku 1784, kdy Edmund Cartwright vynalezl první mechanický tkací stav. Do té doby se výroba omezovala pouze na ruční výrobu v manufakturách, ale industrializací započal proces mechanizace průmyslové výroby, při které se započalo využívání strojních zařízení (např. parní stroj), které používaly jako zdroj energie spalování uhlí, přesněji vodní páru jím vytvořenou. Dopad průmyslové revoluce na společnost byl obrovský, zásadně se změnila všechny obory hospodářství a došlo ke kompletní změně životního stylu. [2] [3]

Druhá průmyslová revoluce proběhla na konci 19. století a je spojována s elektrifikací a vznikem montážních pásových linek. Pro tuto revoluci byl zásadní rok 1879, kdy T. A. Edison vynalezl žárovku a dále rok 1870, kdy společnost Cincinnati nainstalovala ve svém závodě v USA první montážní linku, která přinesla prudký rozvoj masové výroby, jež měla za následek například celospolečenský rozvoj automobilismu, který započal v roce 1908, kdy společnost Ford Motor Company představila dnes již legendární vůz Ford model T. [3]

Třetí průmyslová revoluce je spojena se zaváděním informačních technologií, elektronikou a automatizací. Určení počátku této revoluce je nejednoznačné, protože se jednalo spíše o vyústění přirozeného vývoje inovací než o revoluci jako takovou. Zlomovým bodem byl ovšem rok 1969, kdy byl vyroben první programovatelný logický automat PLC, který měl za následek počátek automatizace procesů v reálném čase. [3]



Obr.2) Přehled průmyslových revolucí v čase [4]

## 2.2 Definice umělé inteligence v kontextu průmyslu 4.0

Umělá inteligence (AI) je kognitivní věda, jejíž výzkumné aktivity jsou zaměřeny na oblasti zpracování obrazu, rozpoznávání plynulé řeči, robotiky, strojového učení a mnoho dalších. [5]

Historicky byly metody strojového učení a umělé inteligence vnímány jako nedostatečně důvěryhodné a často se potýkaly s nedostatkem přesvědčivých faktů, které by dokazovaly, že jsou schopny pracovat opakovaně a důsledně při navrácení počátečních investic. Současně byla výkonnost algoritmů strojového učení vysoce závislá na preferencích a zkušenostech vývojářů, kteří se touto problematikou zabývali. Z toho důvodu byl úspěch umělé inteligence v průmyslových aplikacích silně limitován. Oproti tomu, průmyslová umělá inteligence je systematická disciplína, která se zaměřuje na vývoj, ověření a nasazení různých algoritmů strojového učení v průmyslových aplikacích s udržitelnou výkonností a funguje jako most spojující výstupy akademického výzkumu v oblasti umělé inteligence a odborníky z oblasti průmyslu. [5]

Automatizace řízená umělou inteligencí měla dosud hlavní dopad především na zvýšení produktivity. Mimo to, dnešní průmyslová odvětví čelí novým výzvám konkurenceschopnosti a poptávky na trhu. S tím úzce souvisí, již v předešlé kapitole zmíněné, technologie průmyslu 4.0, které umožní fungování různých odvětví průmyslu efektivním, flexibilním a ekologickým způsobem. [5]

Role nástrojů a technik umělé inteligence v oblasti chytré výroby je horké téma. Revoluce umělé inteligence způsobila, že mnoho firem již významně zaměřuje svoje aktivity právě na tuto oblast. Mnoho zařízení, která jsou využívána v podnicích v sobě mají integrovány senzory, které shromažďují a sdílejí značné množství dat, čímž zachycují mnoho úkonů, které se dějí při provozu daného stroje. Výrobci již pochopili strategický význam analytiky velkých dat, z tohoto důvodu se data stávají klíčovým faktorem zvyšujícím konkurenceschopnost výroby. [6]

Obrovské objemy získaných dat analyzovaných v reálném čase pomocí metod umělé inteligence mohou zlepšit rozhodování a poskytnout lepší přehled o podnikových činitelích jako jsou snížení prostojů strojů, zvýšení efektivity výroby, automatizaci výroby, predikci poptávky nebo optimalizaci zásob ve skladech. [6]

# 3 REŠERŠNÍ STUDIE APLIKACE METOD UMĚLÉ INTELIGENCE

## 3.1 Konvenční metody obrábění

Existuje mnoho přístupů popisujících praktické použití Machine Learning Methods, tedy metod strojového učení, které umožňují strojům učit se, vylepšovat svoje schopnosti a provádět specifický úkol prostřednictvím dat, aniž by byly konkrétně naprogramovány. [7]

Strojové učení lze použít při obráběcích procesech ke zlepšení úrovně kvality produktu, zvýšení produktivity, ke sledování stavu systémů a optimalizaci návrhu a procesních parametrů. Toto je známé pod pojmem Smart Machining, volně přeložené jako chytré obrábění odkazující na nové paradigma obrábění, ve kterém jsou obráběcí stroje plně propojeny prostřednictvím kyber-fyzického systému (CPS). [7]

Algoritmy strojového učení lze rozdělit do tří kategorií na základě učícího systému a typu vstupních dat:

1. **Supervised Learning** (učení s učitelem) – algoritmy jsou trénovány k mapování daných vstupů na odpovídající známé výstupy, které jsou poskytovány lidskými experty. [7]
2. **Unsupervised Learning** (učení bez učitele) – zahrnuje proces vývoje modelu nebo funkce, bez zadávání známých výstupů. Tato metoda se obvykle používá k nalezení smysluplných vzorců nebo klasifikace v rámci velké sady dat. [7]
3. **Reinforcement Learning** (učení posilováním) – proces učení probíhá pomocí předdefinovaného signálu, který stroji umožňuje kvantifikovat jeho výkon. [7]

Algoritmy se snaží provádět dva hlavní úkoly: klasifikaci nebo shlukování, ve kterém jsou data rozdělena do konkrétních tříd, a regresi, ve které je hledán souvislý trend nebo vztah. Různé metody používané k dosažení těchto úkolů určují typ použitého algoritmu, jako jsou Support Vector Machines (SVM), Artificial Neural Networks (ANN), tedy umělé neuronové sítě, Decision Trees (DT), tedy rozhodovací stromy, K-Nearest Neighbors (K-NN) neboli K nejbližších sousedů a mnoho dalších. [7] [8] [9]

Obecně se dá pracovní postup metod strojového učení při aplikaci na metody obrábění popsat Obr.3), na kterém jsou zobrazeny jednotlivé po sobě jdoucí kroky. Zpočátku je nutné definovat problém, který má být vyřešen, následně dochází ke sběru dat, na základě, kterých dochází k modelování algoritmů, ověření jejich správné funkce a posledním krokem je analýza výsledků. Používání tohoto postupu se u jednotlivých metod liší pouze v detailech. [7] [10]



Obr.3) Postup použití strojového učení při řešení problému [7]

### 3.1.1 Frézování

Celkově bylo provedeno čtrnáct případů implementace algoritmů strojového učení na proces frézování. Pomocí těchto algoritmů byly monitorovány a predikovány různé faktory a parametry. Nejběžnějším úkolem bylo sledování stavu nástroje, jeho opotřebení a případný potenciál pro selhání. Pro tyto účely byl vyžadován klasifikační algoritmus, autoři tedy zvolili algoritmy Support Vector Machine (SVM) [11] [12], Artificial Neural Network (ANN) [13] [14], Decision Trees (DT) a dále jejich podtypy Probabilistic Neural Network (PNN) [15] [16] neboli pravděpodobnostní neuronová síť, Backpropagation Neural Network algorithm (BpNN)

[17] [18] a Random Forest (RF) [19]. Byly však zadány další úkoly, například optimalizace procesních parametrů pro snížení nákladů pomocí predikce spotřeby energie, zlepšení kvality obrobků prostřednictvím predikce drsnosti povrchu, řezné síly a deformace obrobku. Pro tyto úkoly autoři také zvolili metodu SVM, ale i další metody jako Gaussian Process Regression (GPR) [20] [21], Nondominated Sorting Genetic Algorithm II (NSGA-II) [22] a další statistické metody. [7] [23]

Výsledkem aplikace těchto metod jsou hodnoty sledování opotřebení nástroje při použití metod K-NN a SVM s přesností 90,26% [24], predikce opotřebení nástroje při použití metody RF s přesností 99,20 % [25], detekce zlomení nástroje metodou SVM s přesností 99,38 % [26] a metodou PNN s přesností 98,60 % [16], predikce spotřeby energie metodou GPR s přesností více než 95% [27], predikce drsnosti povrchu metodou SVM s přesností 86,50% [12], predikce stability chvění metodou SVM s přesností 98,33 % [28], určování specifické řezné síly metodou BpNN s přesností 87,44 % [29] a predikce deformací v tenkostěnném obrobku pomocí Bayesian learning metod s neznámou přesností [30]. [7]

### 3.1.2 Soustružení

U tohoto obráběcího procesu byly metody strojového učení aplikovány na podobné parametry, jako v případě procesu frézování. Ačkoliv pro hodnoty predikce opotřebení nástroje byla použita metoda ANNs, pro predikci drsnosti povrchu byly použity regresivní algoritmy jako Support Vector Regression (SVR) [31] a Polynomial Regression (PR). Dále byla pozornost upředena na detailní použití ANNs na predikci drsnosti povrchu. [18] Kromě toho byly sledovány i další parametry, jako jsou emise uhlíku, mikrotvrdost či predikce velikosti zrn. Na příklad pomocí kombinace RF a Genetic algorithm (GA) byly studovány efekty řezné rychlosti, posuvu, poloměru břítu nástroje a povlakování nástroje, pro dosažení určitých povrchových vlastností, konkrétně mikro tvrdosti způsobené procesem obrábění a velikost zrn. [19] Dalším zjišťovaným parametrem byla predikce emisí uhlíku produkovaná v průběhu procesu soustružení pomocí regrese a metody Multi-Objective Teaching Learning Based Optimization (MOTLBO). [32] [7]

Výsledky aplikací těchto metod jsou následující: hodnoty predikce drsnosti povrchu pomocí metody Multiple Linear Regression (MLR) s přesností 80,80 % [33], predikce drsnosti povrchu, řezné síly a životnosti nástroje metodou SVR a ANNs s přesností okolo 93% [34], predikce mikrotvrdosti a velikosti zrna pomocí metody RF a GA s přesností 96,50 % [19], kvantifikace emisí uhlíku a jejich predikce společně s optimalizací řezných parametrů metodou MOTLBO s přesností okolo 95 % [32], predikce opotřebení nástroje a rozpoznání vzorku pomocí metod BpNN a DNA-based computing s přesností okolo 75% [35] a sledování nástrojových podmínek metodou K-star algorithm s přesností 78,69 % [36]. [7]

### 3.1.3 Broušení

Na proces broušení byla na parametry drsnosti povrchu a tvaru povrchu aplikována metoda Interpolation-factor SVM [37]. Jako vstupní parametry byly použity hodnoty akustických emisí, brousící síly a vibrací. [7]

Výsledky u metody broušení jsou při aplikaci metody Interpolation-factor SVM hodnoty drsnosti povrchu s přesností 85,19 % a tvaru povrchu s přesností 75,93 % [37]. [7]

### 3.1.4 Vrtání

Podobně jakou u předchozích metod bylo i u operace vrtání dosaženo predikce kvality produktu pomocí sledování procesních parametrů, jako jsou axiální síla na vrtáku, řezná síla a kroutící

moment. Kruhovitost, rozměrové odchylky, delaminace a drsnost povrchu obrobených polymerových desek vyztužených uhlíkovými vlákny byly ověřovány pomocí metod strojového učení a rozpoznávání vzorů známých jako Logical Analysis of Data (LAoD) neboli logické analýzy dat [38]. [7]

Výsledkem aplikace metody LAoD jsou informace sloužící k ohodnocení kvality obrobku a jeho geometrického profilu s přesností 94,60 % [38].

### **3.1.5 Vyvrtávání**

Při procesu vyvrtávání lze zvýšit kvalitu povrchu pomocí prevence chvění. Autoři se zaměřili na parametry rychlost vřetena, hloubku řezu, posuv a generované chvění. Funkce byly extrahovány z vibračních signálů pomocí Discrete Wavelet Transform neboli diskrétní vlnkové transformace a klasifikovány na stabilní, přechodné nebo chvějící třídy pomocí SVM [39]. [7]

Výsledkem je funkce predikce chvění pomocí metody SVM s přesností 95 % [39]. [7]

## **3.2 Nekonvenční metody obrábění**

Ačkoli je případů procesu nekonvenčního obrábění v porovnání s konvenčními metodami méně, učící algoritmy byly implementovány na takové faktory, jako jsou zlepšení předpovědi drsnosti povrchu za účelem zlepšení kvality. Nicméně, vzhledem k nízké produktivitě těchto metod, jedním z hlavních účelů byla optimalizace procesních parametrů pro maximalizaci rychlosti odebrání materiálu. [7]

### **3.2.1 Řezání laserem**

Tato metoda je již běžně používána v průmyslových procesech, avšak doposud nebyly nalezeny optimalizované procesní parametry, zejména pro jemné aplikace, jako je například mikro obrábění. Aplikací a porovnáním různých algoritmů strojového učení, lze predikovat výslednou úroveň kvality obrobeného povrchu, rozměrové vlastnosti a míru produktivity obrábění laserem. [40] [7]

Výsledkem aplikování těchto metod je nástroj pro predikci kvality obrobeného povrchu, rozměrových vlastností a míry produktivity laserového obrábění pomocí metod Linear Regression, ANN, DT a K-NN s přesností 88,70 % v případě predikce hloubky záběru pomocí metody ANN a s přesností 76,90 % v případě predikce rychlosti odebrání materiálu pomocí metody DT. Výsledky tedy naznačily, že metoda DT byla přesnější v predikci rychlosti odebrání materiálu, zatímco ANN byly účinnější při modelování rozměrových vlastností po obrábění. [40] [7]

### **3.2.2 Řezání vodním paprskem**

Použití metod umělé inteligence se u této metody zaměřuje především na predikci drsnosti povrchu. Té bylo dosaženo pomocí různých typů ANNs, jako jsou Feedforward, Backpropagation a extrémní strojové učení [41]. [7]

Nejlépeších výsledků predikce drsnosti povrchu bylo dosaženo pomocí hybridního algoritmu, který kombinuje Grey Relational Analysis pro výběr prvků a metodu SVM s přesností výsledků 99 % [41], v případě použití metod ANN, GPR a extrémního strojového učení s přesností 96,65 % [42] a v případě použití metod NNs s přesností 96,99 % [43] a při použití metody Regression model s přesností výsledků 99 % [43]. [7]

### 3.2.3 Elektroerozivní obrábění

Ačkoli bylo u této metody vynaloženo úsilí predikovat drsnost povrchu, hlavním účelem implementace metod strojového učení je predikovat a maximalizovat parametr rychlosti odebrání materiálu především kvůli nízké produktivitě, kterou je tato metoda charakteristická. Těchto úkolů bylo dosaženo více způsoby, jednak pomocí koinicace metod ANNs a EAs [44], v dalším případě pomocí metody BpNN s částečnou Swarm optimalizací a v neposlední řadě za použití metod Feed-forward BpNN s GA. Tyto evoluční algoritmy byly použity především pro účely optimalizace. [7]

Výsledkem aplikace těchto metod je nástroj sloužící pro odhad maximální řezné rychlosti a optimalizace parametrů obrábění pro maximální rychlost odebrání materiálu při použití metod Feed – forward BpNN a GA s přesností 96,06 % [45]. [7]

### 3.2.4 Elektrochemické obrábění

Vzhledem k podobným procesním vlastnostem byly v tomto případě, stejně jakou u elektroerozivního obrábění, implementovány učící algoritmy pro predikci a maximalizování maximální rychlosti odebrání materiálu [46]. Bylo použito metody Teaching Learning Based Optimization (TLBO), která dokázala překonat metodu Artificial Bee Colony (ABC) díky menšímu počtu požadovaných opakování. Metoda TLBO byla také implementována do hybridního procesu elektrochemického erozivního obrábění, čímž došlo ke zvýšení maximální rychlosti odebrání materiálu o 18 % ve srovnání s metodou ABC [46]. [7]

## 3.3 Stavba obráběcího stroje

V oblasti metod obrábění v kontextu aplikací metod umělé inteligence bylo zaměřeno mnoho úsilí na zlepšení samotného obráběcího procesu, ale kromě toho lze také zlepšit strukturu samotného obráběcího stroje, aby se dosáhlo sebekontroly nebo diagnostiky a samočinného přizpůsobení vnějším vlivům. [7]

Tuto myšlenku rozvíjí studie čínských vědců [47], při které odborníci vyvinuli model kompenzace tepelné chyby studiem vztahu mezi teplotou na citlivých místech a generovanou tepelnou chybou. Z různých algoritmů, které implementovali, dosáhli nejpresnějších výsledků s metodou SVM v kombinaci s metodou Fuzzy Clustering Analysis a Grey Correlation. [7]

Další je studie publikovaná korejskými odborníky, ve které se zaměřili na vývoj sebeoptimalizačního řídicího systému, který může nezávisle upravovat parametry procesu na základě vnějších vlivů. V tomto případě se k predikci opotřebení nástroje a stanovení optimálního posuvu používá metoda fuzzy logic v kombinaci s ANN. [48]

## 3.4 Výběr vhodného materiálu pro výrobu produktu

Tato kapitola se zaměřuje na průzkum nejnovějších výpočetních metod pro výběr optimálního materiálu k výrobě produktu v průmyslu 4.0. Rekognoskuje, jakým způsobem mohou nejrelevantnější metody umělé inteligence pomáhat ve výrobním procesu při výběru nejvhodnějšího materiálu pro zamýšlenou aplikaci, podle jejich vlastností a provozního chování. [49]

Technologie v současné době umožňují vyrábět materiály s obrovskou škálou vlastností s tím, že tyto materiály mohou pracovat různými způsoby, záleží pouze na prostředí a na pracovních podmínkách, kterým jsou tyto materiály vystaveny. Díky tomu je dostupné

obrovské množství dat a situace se již stává pouze pomocí běžných výpočetních metod nezvladatelnou. [49] [50] [51]

Nicméně pro získání spolehlivých a užitečných informací, které nám umožní lepší možnosti při rozhodování, je nutné tato data zpracovat vhodným způsobem. S tím si dokážou poradit metody umělé inteligence, které mohou konstruktérům pomoci při výběru vhodného materiálu pro daný úkol. Při snížení nákladů za údržbu jsou schopny zvýšit celkový výkon a bezpečnost a umožní systému fungovat v extrémnějších podmínkách. Metody umělé inteligence mohou být integrovány v rámci nástrojů, které mají konstruktéři běžně k dispozici a mohou vzít v úvahu i jiné faktory, než čistě technického a ekonomického rázu, například faktory prostředí, výkonnostní faktory a mnoho dalších. [52] [53] [54] [55] [56]

Studované metody v této oblasti jsou ohraničeny do dvou kategorií: techniky Supervised Learning (SL) a techniky Unsupervised Learning (UL). Toto rozdělení umožňuje celkové porovnání dvou hlavních metod strojového učení a pomáhá určit, která kategorie dokáže přinést lepší výsledky při aplikacích příbuzných výběru materiálu pro průmyslovou výrobu. Dále má toto srovnání velký význam při trénovací fázi pro získání dobrých výsledků, je totiž v případě druhé metody zapotřebí mnohem více vstupních dat. [57] [58] [59]


### Decision Trees (DT)

Decision Trees, neboli rozhodovací stromy jsou sady metod kategorizované jako techniky Supervised Learning, které jsou obecně používány pro vytváření klasifikací. Cílem této metody je vytvoření modelu, který bude schopen predikovat hodnotu sledované proměnné. Je založen na řadě rozhodovacích pravidel odvozených z vlastností tréninkových dat. [60] [61]

Decision Trees se učí ze vstupních dat modelovat hranice, které umožňují popsat různé kategorie. Jedna ze vstupních proměnných je vybrána v každém vnitřním uzlu stromu podle metody, která závisí na vybraném algoritmu. Každá větev podřízeného uzlu odpovídá sadě hodnot vstupní proměnné, takže všechny větve pokrývají všechny varianty vstupní proměnné. Každý list (nebo koncový uzel stromu) představuje hodnotu (nebo rozsah hodnot) cílové proměnné. Kombinace hodnot vstupních proměnných je reprezentována cestou z kořene do listu. Strom je obvykle konstruován rozdělením všech dat do podskupin podle hodnoty vstupní charakteristiky. Tento proces je opakován rekurzivně v každé podskupině, takže se jedná o rekurzivní část. [61] [62]

Rekurze je v uzlu kompletní, jestliže je dosažena požadovaná hloubka rekurze, nebo v případě, že separace již nezlepšuje predikci. Tento proces se nazývá Top-Down Induction of Decision Trees (TDIDT) a jedná se o nenasytný algoritmus, poněvadž je sledován každý uzel stromu pro optimální distribuci, a to kvůli zisku nejlepší možné participace v celém rozhodovacím stromu. U metody DT je tento způsob nejběžnější strategií učení z dat. Obr.4) zobrazuje hranice naučené pomocí tréninku rozhodovacího stromu s dvou rozměrným označeným data setem. [60] [62] [63]





Obr.4) Příklad rozhodovacího stromu [49]

Výhody této metody jsou:

- má nízké výpočetní požadavky;
- DT nevyžadují předzpracování dat a učicí proces je obvykle rychlý. [49]

Nevýhody této metody jsou:

- DT jsou dimenzovány velmi nadměrně a mají tendenci upřednostňovat určitou skupinu před jinou;
- učení optimálního rozhodovacího stromu je známé svým NP-complete problémem (Nondeterministic Polynomial Time). [49]

Metoda DT může být použita jako pomoc při výběru vhodného materiálu pro průmyslovou výrobu. Pro příklad, pokud máme určené hranice pracovních podmínek tekutinového potrubního zařízení a jeho konstrukční materiál, můžeme vycvičit DT algoritmus tak, že nám dokáže nabídnout nejvhodnější materiál, který by měl být použit pro výrobu nového potrubí. [49]

#### Neural Network (NN) – Multi-Layer Perceptron (MLP)

MLP je algoritmus Supervised Learning schopný učit se nelineární funkce tréninkem na označených data setech, které mohou být využity pro klasifikaci a regresi. S ohledem na topologii připojení nejjednodušších modelů dopředné neuronové sítě, které se skládají pouze z jednoho neuronu a jsou označovány jako perceptrony, mohou být definovány tři typy vrstev: vstupní vrstva, která zahrnuje všechny perceptrony, které získávají data z externích zdrojů; výstupní vrstva, která zahrnuje všechny perceptrony, které vracejí výsledky (informace) a skrytá vrstva, která obsahuje všechny ostatní perceptrony, které nekomunikují s okolím sítě, toto rozdělení je shrnuto v Obr.5). [64] [65] [66]


Výhody MLP jsou:

- schopnost učení nelineárních modelů;
- schopnost získávání široké komplexnosti. [49]

Nevýhody MLP jsou.

- je náchylný k nalézání lokálních minim a jeho trénink je pomalý a složitý proces;
- vyžaduje vyladění velmi důležitých parametrů před zahájením samotného tréninku. [49]

MLP algoritmus může být používán k rozpoznávání všech druhů vzorů v celém data setu. Například, pokud máme širokou a stručnou databázi materiálů, můžeme vytrénovat MLP algoritmus pro doporučení nejlepšího materiálu pro výrobu průmyslové součásti založené na všech známých vlastnostech a všech uvedených okrajových podmínkách. Výsledný algoritmus bude shrnovat všechny znalosti obsažené ve vstupních datech. [49]



Obr.5) Příklad vrstev neuronové sítě [49]

### K-means Clustering algorithm

Data Clustering je skupina metod pro analýzu dat založených na technikách Unsupervised Learning. Jejich cílem je rozdělit sadu datových vektorů do různých homogenních množin (shluků) pro vytvoření datových podmnožin, jež sdílejí společné vlastnosti, které často odpovídají kritériím blízkosti (informační podobnosti). Tato kritéria jsou definována jako běžné hodnoty nebo třídy vzdálenosti mezi objekty. [67] [68]

Strategie shlukování je velmi důležitá, pokud jde o získání dobrých výsledků a do značné míry závisí na setrvačnosti datových množin a podmnožin. V tomto případě je pojem setrvačnost myšlena jako měřítko vzdálenosti, pokud jde o informace, které existují mezi dvěma datovými vektory a dvěma datovými skupinami. Za účelem získání dobrého rozdělení je vyžadováno minimalizovat setrvačnost mezi podskupinami. Zejména, kvůli dosažení skupin, co nejvíce homogenních, jak jen je možné a kvůli maximalizování setrvačnosti pro získání dobře rozlišitelných podmnožin. [49] [68]

Tyto metody se běžně používají při klasifikaci (která eventuálně umožňuje zestručnění dat), segmentaci dat a hledání odlehlých hodnot. Existuje mnoho strategií shlukování a metod setrvačného řízení, které dávají různé algoritmy, jež obecně dosahují zřetelných výsledků. Nejběžněji používaným algoritmem je K-means. Příklad rozdělení data setu pomocí algoritmu K-means je zobrazen v Obr.6). [49] [69]

K-means metody vyžadují specifikování zamýšleného počtu shluků a často jsou označovány jako Lloydův algoritmus. Ten seskupuje data prostřednictvím strategie, která rozděluje vzorky do podskupin stejného rozptylu a minimalizuje setrvačnost uvnitř shluku. [49] [70]



Obr.6) Příklad požití K-means Clustering algoritmu ve dvou rozměrné oblasti

Výhody Clustering algoritmů jsou:

- jedná se o efektivní komplexní řešení, které je schopné řešit tyto problémy;
- K-means je obecně velmi rychlý, ale vyskytují se zde i případy, u kterých je sjednocování opožděno. [49]

Nevýhody Clustering algoritmů:

- K-means je známý pro své suboptimální výsledky a také svým NP-complex problémem;
- K-means se pyšní nacházením shluků stejné velikosti a tím, že počet shluků je vstupem. [49]

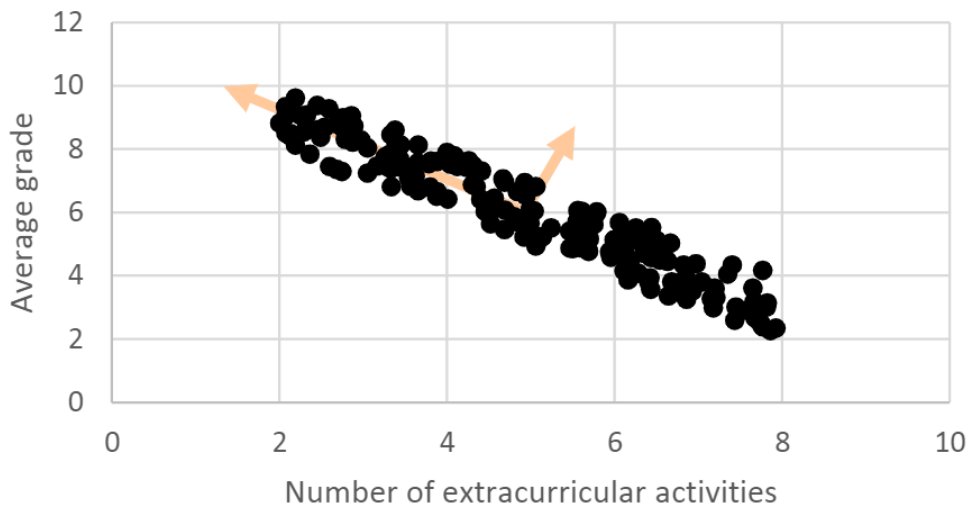
Tyto metody mohou sloužit k provádění seskupení komponent, které sdílejí stejné funkce nebo jsou vystaveny stejným pracovním podmínkám. Obecně se dá prohlásit, že mechanismy, které pracují pod stejnými okrajovými podmínkami mohou používat stejné výrobní materiály. Na příklad, pokud máme data o okrajových podmínkách všech existujících potrubí ve velkém průmyslovém závodě, tento typ algoritmu může být použit pro nalezení vzorů použití nebo k vytvoření shluků, které mohou být užitečné při tvorbě nového návrhu. [49]

### Principal Component Analysis (PCA)

PCA odkazuje na skupinu metod, které se používají k provádění klasifikací tím, že se pokoušejí provést redukci rozměrů dat. Mohou být použity také ke zrychlení ostatních algoritmů snížením velikosti ukázkových vektorů. Hlavní součásti data setů jsou směry, ve kterých je větší odchylka a nějakým způsobem představují základní strukturu. [71] [72]

Způsob, jakým je odchylka rozložena v mračnu dat dává představu o směrech, ve kterých je více informací. Ty, ve kterých jsou vzorky více rozprostřeny, budou mít větší význam než ty, které jsou konstantní. Hlavní součásti dovolují shrnout data eliminující zbytečné nebo málo rozlišující informace a zvýraznit ty, které budou pravděpodobně důležitější. [71] [72]

Tyto algoritmy mají omezení, která z nich dělají lepší nástroj, když jsou data organizována do lineárního členění, to znamená, když jsou data organizována tak, že mohou být promítnuta do roviny bez vytváření příslušného zkruslení. PCA algoritmus minimalizuje množství chyb, které nastávají při promítání dat do rozměru roviny. Současně s tím bude algoritmus hledat orientaci roviny, která maximalizuje odchylku. Obr.7) zobrazuje dvě hlavní součásti data setu, které ukazují, že pro data existuje směr s vysokou odchylkou. [49] [71] [72]



Obr.7) Příklad PCA algoritmu v dvou rozměrné oblasti [49]

Výhody PCA jsou:

- PCA dovoluje snížit rozměrnost dat;
- PCA je polynomičtý algoritmus. [49]

Nevýhody PCA jsou:

- PCA předpokládá linearitu dat a tato pozorovaná data jsou lineární kombinací určité báze;
- PCA se zcela spoléhá na průměr a odchylku, což může způsobit statistické problémy. [49]

Tyto algoritmy mohou být použity pro určení toho, které vlastnosti jsou nejdůležitější při provádění výběru materiálu, a proto omezují rozsah možností. [49]

### 3.5 Automatizační řízení

Tato kapitola, vychází ze studie, která byla vydána čínskými vědci v rámci 3rd International Conference on Mechatronics and Intelligent Robotics (ICMIR-2019). Tato studie se zaměřuje na aplikaci metod umělé inteligence v oblasti průmyslového automatizovaného řízení, které dosahuje skvělých výsledků. [73]

Jedna skutečnost musí být ujasněna, používání technologií umělé inteligence se stalo trendem, ale neznamená to, že současné technologie umělé inteligence již úplně dozrály. Jinými slovy, technologie umělé inteligence jsou ve stádiu vývoje, stále však existuje mnoho problémů, které je třeba optimalizovat a vylepšovat. [73]

Technologie umělé inteligence mají v oblasti automatizace širokou škálu aplikací. Tyto aplikace jsou dále ilustrovány v pěti hlediscích: zjednodušený proces, diagnostika poruch, elektronické řízení, elektrická zařízení a každodenní provoz. [73] [74]

#### 3.5.1 Zjednodušení procesu

Proces automatizace je velmi složitý proces, každý krok a propojení jsou v úzké souvislosti s velmi přísným postupem a požadavky. Pokud se stane, že u některého spojení či kroku nastane problém, má to na celý proces dopad s vážnými důsledky. Není moudré plýtvat pracovní silou, ale z ekonomického pohledu jde o vážné ztráty. Pokud jsou však na proces automatizace aplikovány metody umělé inteligence, lze celý proces zrychlit a zjednodušit. Například situace,

kdy nastane porucha, oprava zařízení, detekce prostředí atd., to vše lze vyřešit za pomoci metod umělé inteligence. Manuální postup je velice jednoduchý, což výrazně zvyšuje efektivitu obsluhy. [73] [75]

### 3.5.2 Diagnostika poruch

V současném procesu automatizace řízení může způsobit selhání zařízení mnoho subjektivních a objektivních faktorů jako jsou například zemětřesení, tsunami, tajfuny, vlhkost, nesprávná obsluha či zanedbávání zřejmých potíží na zařízení. Tyto faktory budou mít s postupem času čím dál větší dopad na proces automatizace řízení. Pokud však budou tyto poruchy řešeny účinně a včas, nezpůsobí další poškození. Pokud ovšem budou tyto poruchy zanedbány, mohou způsobit větší bezpečnostní rizika. [73]

Zavedení metod umělé inteligence nejen způsobí výrazné zjednodušení procesu automatizace, ale také zrychlí diagnostiku poruch. V současné době jsou metody Expert system, Fuzzy Theory a Neural Network nejběžněji používanými metodami pro diagnostiku poruch. Pokud tyto metody zkombinujeme navzájem, doba detekce se výrazně zkrátí a současně s tím dojde ke zpřesnění výsledků detekce. [73]

### 3.5.3 Elektronické řízení

Elektronické řízení je základním prvkem celého procesu automatizace. Určuje nejen operační rychlost a efektivitu výroby vedenou pomocí automatizačního řízení, ale také dokáže řídit celý automatizační proces. Po zavedení technologií umělé inteligence do procesu elektrického řízení, se proces řízení stal více vědecktější. Kromě toho byla výrazně zvýšena provozní účinnost zařízení. Technologie umělé inteligence efektivně zvládají řízení zpracování informací a výrobní náklady v procesu automatizačního řízení, čímž je automatizační řízení účinnější a sofistikovanější. [73]

#### Fuzzy řízení

Teoretickým základem Fuzzy řízení je teorie fuzzy lingvistických proměnných a Fuzzy reasoning. Expertní zkušenost je pravidlem fuzzy řídicí technologie. Ve skutečném procesu řízení je hlavním nástrojem Fuzzy řízení tzv. Fuzzy ovladač, struktura s uzavřenou smyčkou se spojeními zpětné vazby. Pravidlo uvažování rámce Fuzzy řídicího systému je založeno na Fuzzy logice, která kombinuje digitální řídicí systém s počítačovým řídicím systémem, což se ukazuje jako profesionální a efektivní způsob. [73]

#### Expertní řízení

Takzvané Expertní řízení je založeno na teorii a zkušenostech odborníků v souvisejících oborech v kombinaci s příslušnými znalostmi o elektronickém řízení pro napodobování některých operací v této oblasti. Přesněji řečeno, odkazuje na zkušenosti pochopit proces řízení. Technologie expertního řízení má tyto výhody: [73]

- skvělá přizpůsobitelnost a nastavitelnost;
- parametry ovladače mohou být přizpůsobeny na nejrůznější situace;
- efektivita technologie expertního řízení je velmi vysoká, její použití je široce flexibilní a může se přizpůsobit mnoha různým stylům ovladačů;
- vynikající stabilita a bezpečnost s ohledem na kvalitativní analýzu, která má komplexní ohled a je velmi bezpečná a konzervativní. [73]

### Řízení pomocí Neural network

Teoretickým základem řízení pomocí Neural Network je aktivita neuronů lidského mozku a pravidla neuronů lidského mozku poskytují základní model řízení pomocí Neural network. V současné době je velké množství odborníků na oblast řízení pomocí Neural Network, takže rychlost vývoje Neural Network řízení je velmi vysoká a bylo dosaženo mnoha úspěchů. Výzkum řízení pomocí Neural Network se vyvíjí velmi rychle, což přináší skvělé výsledky pro aplikaci automatizačního řízení. Konkrétně je funkce Fuzzy řízení realizována hlavně na základě stejnosměrného a střídavého měniče. Při procesu stejnosměrného přenosu probíhá řízení přenosu pomocí prvků Mamdani a Sueno, první zajišťuje řízení rychlosti přenosu a druhý má na starosti spouštěcí řízení. V procesu střídavého pohonu musí být automatické řízení založeno na Fuzzy ovladači. [73]

#### **3.5.4 Elektrická zařízení**

Elektrická zařízení jsou obecně složitá a vyžadují, aby byla obsluha kompetentní, s určitým množstvím znalostí a dovedností. Při navrhování elektrických zařízení lze technologii umělé inteligence použít ke zjednodušení systému elektrických zařízení a posílení používání technologie umělé inteligence v těchto zařízeních. Pomocí technologie umělé inteligence mohou být některé parametry elektrických zařízení nastaveny počítačem, takže rychlost provozu těchto zařízení může být svižnější. Operátoři budou tato zařízení také snadněji obsluhovat. [73]

#### **3.5.5 Každodenní provoz**

Automatizační řízení je proces úzce související s každodenním životem lidí, jakožto například řízení energetické sítě, získávání dat atd. Příkladem je možno uvést rozvodnou síť, jejíž každodenní provoz je velmi komplikovaný, nejen počet vedení a zařízení v rozvodné síti je velmi velký, ale také počet připojených uživatelů je masivní, což vede k obrovské pracovní zátěži operátorů. Pokud je použita technologie umělé inteligence, lze některé základní algoritmy předat technologii umělé inteligence a tím složitý provozní proces zjednodušit. Operátor potom nemusí chodit sem a tam, aby shromažďoval a zpracovával data, stačí použít počítač k dohledu a dálkovému řízení procesu elektrického řízení. Kromě toho mohou technologie umělé inteligence zjednodušit operační rozhraní počítače a zálohovat data včas tak, aby se předešlo nehodám. V minulosti, kdy probíhal ruční sběr dat, nevyhnutelně docházelo k určitým chybám souvisejícím s lidským faktorem. Technologie umělé inteligence mohou sestavovat účinné formuláře, které pomáhají při shromažďování dat, snižují pracovní vytížení operátorů a zvyšují jejich efektivitu práce. [73]

### **3.6 Průmyslová výroba**

Tato kapitola, jež vychází ze článku vydaného jihoafrickými odborníky v rámci 2nd International Conference on Sustainable Materials Processing and Manufacturing (SMPM 2019) se zaměřuje na implementaci metod umělé inteligence v oblasti výrobního průmyslu, zejména na produkty z oceli. [76]

Internet of Things (IoT) a Cyber Physical System (CPS) jsou poslední témata zájmu ve výrobním sektoru. Dosud jsme byli svědky adaptace senzorů ve výrobních závodech, nástrojů a inteligentních zařízení propojených dohromady se senzory. Senzory však shromažďují nejrůznější množství dat z inteligentních zařízení propojených dohromady ve výrobním prostředí. Dá se předpokládat, že zpracovatelský průmysl bude i nadále plnit očekávané cíle a

bude schopný dodávat vysoce kvalitní produkty, které jsou bezpečné a musejí být efektivní z hlediska nákladů. Průmyslová výroba může utrpět ránu kvůli nesplnění těchto cílů. Produkty z oceli však mohou mít odchylku v parametrech jako jsou tvar, vzhled, drsnost, rozměry a mnoho dalších, které se neshodují se specifikacemi pro dané normy. Cílem prvků, jako je monitorování průmyslových zařízení, je dosáhnout snížení výrobních nákladů, zlepšení výkonnosti systému, zvýšení kvality produktu a včasné odhalení nepřesností výrobků. [77] [78] [79]

Diagnostika detekce chyb pomáhá rychle identifikovat vady výrobků produkovaných ve výrobním průmyslu. Proces identifikace chyb lze provést pomocí vizuální kontroly, která se ovšem nedoporučuje, protože je časově náročná a může vést k nepřesným rozhodnutím. Dalším způsobem je použití nástrojů a vybavení, které dokážou chyby zachytit. Pokud se tyto chyby v oceli nezjistí hned na začátku výrobního procesu, mohou mít za následek selhání produktu, následnou nedostupnost produktů a materiálů, které nelze použít. Zde je třeba najít vzory ve vygenerovaných datech pro přesné rozhodování. [76]

Machine Learning (ML) je odnoží umělé inteligence, jejíž techniky se schopností učení systému z předchozích znalostí kvůli rozvoji nebo vytvoření predikcí pro aktuální a budoucí události, používá a využívá mnoho průmyslových odvětví v různých doménách. Techniky ML lze použít pro identifikaci vzorů a detekci poruch jako způsobu asistence v monitorování procesů a účinných procesů ve výrobě. Účelem této studie je identifikovat a analyzovat techniky, které lze použít k detekci a diagnostice poruch. Diagnostika poruch se snaží najít vadná místa a určité špatné podmínky v rámci různých výrobních produktů a systémů. Proto se měření konkrétního produktu používají ke sledování neodpovídajícího stavu tohoto produktu. [76] [80] [81]

### Support Vector Machine

Support Vector Machine (SVM) je velmi populární algoritmus strojového učení, který má výhodu v použití různých funkcí jádra. Jádro funguje v práci SVM způsobem, který mapuje prostor vstupních funkcí v případech, kdy se data změni lineárně oddělitelné. Tato konkrétní metoda je velmi populární pro manipulaci s velkými daty a skládá se ze dvou kategorií, které slouží pro účely klasifikace a regrese. Používá tzv. hyper plán, který využívá maximální okraj oddělením dvou hranic. [80] [82] [83]

### Random Forest

Random Forests (RF) patří do kategorie metody Decision Trees (DT) a jsou velmi populární z různých hledisek aplikace strojového učení, které mohou být rozděleny na úkoly jako jsou regrese a klasifikace pro Supervised Learning. [80]

Výhodou RF je, že jsou snadno srozumitelné, zvládají velké data sety, nevyžadují velkou předpřípravu dat a mají vestavěný výběr funkcí. [76]

Nevýhodou RF je, že jsou známé pro předimenzování během predikce a mohou být složité při implementaci. [76]

### **3.6.1 Metalurgické průmyslové odvětví**

Ve studii v metalurgickém průmyslovém odvětví byla aplikována extrakce vlastností metody RF na testování schémat diagnostiky chyb, která byla testována na jednoduchém nelineárním systému a dvou chybách benchmarkového procesu Tennessee Eastman. Autoři naznačují, že RF má schopnost být robustní v diagnostice poruch při monitorování procesů. Za účelem

zjištění závad senzorů v topných, ventilačních a klimatizačních systémech, kvůli datům výkonu v minulosti, autoři navrhli kombinaci Rough Set Approach a Artificial Neural Network. Jejich model se ukázal jako velmi úspěšný, protože použili Rough set pro snížení zbytečných vlastností. Metoda Support Vector Machine je porovnávána s metodou Machine Learning pro detekci anomálií v rotujících součástech a cílem bylo provést klasifikaci defektů pomocí testů ložisek s ověřenými vadami. Výsledek ukázal, že metoda Machine Learning byla výkonnější než metoda SVM. [78] [79] [81]

Navíc, srovnání v této konkrétní studii používá optimalizovaná data z neoptimalizovaných sad senzorů pomocí metod SVM, Weighted K-Nearest Neighbor (WKNN) a DT. S cílem kategorizovat poruchy různých forem podle stupně závažnosti, testovali algoritmy pomocí známých dat pro predikci neznámých výsledků. Techniky jako je výběr prvků jsou nejoblíbenější v oblasti Machine Learning. Na toto téma byla provedena studie, kde autoři navrhli techniku nelineární SVM výběru prvků za účelem řízení monitorování procesů a detekce poruch jako součást vyhodnocovacího procesu řazení prvků za účelem asistence v procesu diagnostiky poruch. Jejich metoda výběru prvků byla úspěšná při zlepšování přesnosti detekce a diagnostiky chyb. [76] [82] [84]

Další studie experimentovaly s nově navrhovanou technikou pro detekci a diagnostiku poruch, která je založená na metodě SVM jedné třídy. Tato metoda využívá použití eliminace rekurzivního prvku SVM pro metodu výběru prvku. Nicméně tento přístup byl zkoumán za účelem porovnání konvenčních technik, jakou jsou Principal Component Analysis (PCA) a Dynamic Principal Component Analysis (DPCA) pro měření výkonu s veličinami jako jsou míra falešných poplachů, prodleva detekce a rychlost detekce poruch. Jejich metoda byla vyhodnocena jako robustnější oproti PCA a DPCA pro detekci a diagnostiku poruch. V jiné studii se zaměřili na aplikaci metody RF s cílem použít měření vzdálenosti podobnosti jako veličinu pro detekci anomálií v polovodičovém výrobním procesu s využitím experimentálních průmyslových dat. Tato metoda přesně detekuje vadné základní disky a dále je RF metoda navrhována jako nejvhodnější pro detekci anomálií pomocí Big data. [76] [85] [86]

### Výsledky

Výsledky ukazují, že metoda RF je robustní vůči jiným algoritmům pro klasifikaci chyb. Metoda RF dosáhla nejvyšší přesnosti, konkrétně 77,8 % oproti metodám SVM s dosaženou přesností 73,6 % a ANN s přesností 69,6 %. Autoři nicméně chtěli dále testovat dopad ladění parametrů a hyper parametrů. Pro tento úkol vynechali metodu ANN a zaměřili se pouze na metody SVM a RF. Pro vyladění algoritmů použili nástroj Grid search a na výsledky použili také K-fold validaci. Výsledky, které získali ze simulace byly pomocí SVM lepší, než při úplném ladění algoritmů a pro RF redukovali některé parametry. Výsledky s použitím nástroje Grid search ukazují nejlepší výsledky parametrů pro metodu SVM a největší přesnost 77,8%. RF dosáhly nejlepší parametrů s přesností 75,5 %. Autory jsou dále uváděny další způsoby porovnání s metodou Random Search, pro účely této studie však nebyly použity. Paměť bere v úvahu počet pravdivých pozitiv vydělený počtem pravdivých pozitiv v součtu s nepravdivými negativy. Přesnost je nicméně počet skutečných pozitiv vydělený počtem skutečných pozitiv v součtu s počtem nepravdivých pozitiv. V tomto případě by to znamenalo, že by chyby správně klasifikované byly děleny chybami správně klasifikovanými v součtu s chybami nesprávně klasifikovanými jako chyby. [76]



### 3.7 Energetika

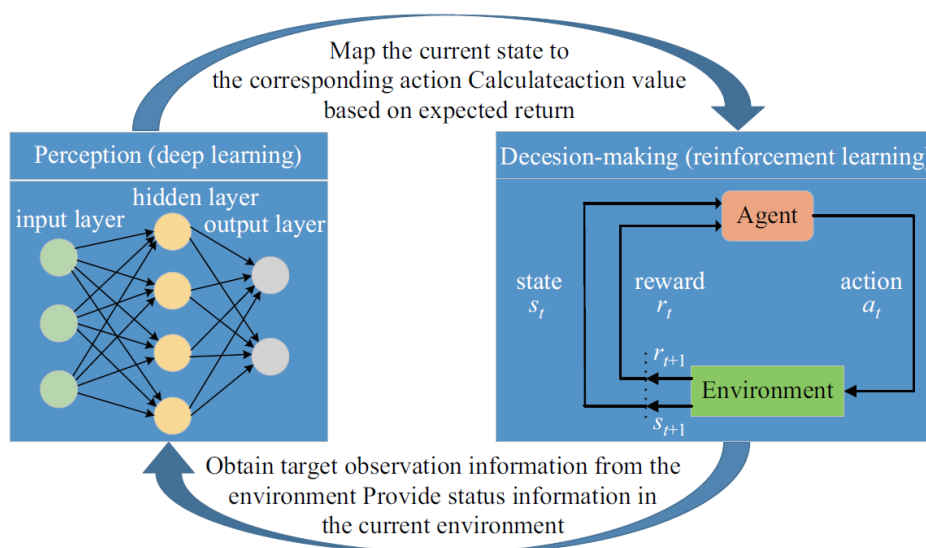
Energetická přenosová soustava je komplexní, dynamická a rozsáhlá síť zařízení, která zajišťují přenos elektrické energie od výrobců ke spotřebitelům. Tato soustava prošla desetiletími vývoje. Během toho, ekonomické, technologické, enviromentální a politické iniciativy transformovaly konvenční sítě na více komplexní, robustní, efektivní a udržitelné inteligentní sítě. Inteligentní sítě využívají obousměrný tok energie doprovázený obousměrným tokem informací mezi všemi účastníky, včetně výrobců, spotřebitelů, provozovatelů přenosových a distribučních systémů a vyrovnávacích agregátorů poptávky. Takové faktory přinesly problémy energetické přenosové soustavě z mnoha hledisek. V první řadě vysoké využití energie z obnovitelných zdrojů (jako jsou solární a větrná energie) přineslo nejistotu přísunu elektrické energie do soustavy. Navíc díky deregulaci trhu s elektřinou a aktivní účasti zákazníků je složitější najít řešení, které umožní začlenění distribuovaných energetických zdrojů. [87] [88] [89] [90] [91]

K vyřešení těchto problémů jsou potřebné účinné metody plánování a provozování soustavy. Tato probíhající transformace sítí vede ke zvýšené nejistotě a složitosti v obou obchodních transakcích a fyzického toku elektřiny. Navíc, obrovský přísun informací a fluktuace dat dělá z rozhodovacího procesu velmi složitý problém. Proto budoucí inteligentní sítě potřebují systémy, které budou schopny monitorovat, predikovat, rozvrhovat, učit se a rozhodovat o spotřebě a produkci energie v reálném čase. To vyžaduje efektivnější a inteligentnější řešení, jako je metoda Deep Reinforcement Learning. [92] [93] [94] [95] [96]

#### Deep Reinforcement Learning

Reinforcement Learning, odvozená z neutrálního podnětu a odpovědi, je metoda z kategorie Machine Learning. Stala se populární díky svému úspěchu při řešení náročných úkolů sekvenčních rozhodovacích problémů. Její kombinace s metodou Deep Learning, nazývaná Deep Reinforcement Learning (DRL), zaznamenala velké úspěchy v oblastech počítačových her, robotiky, zpracování přirozeného jazyka, financí a obchodního řízení. [97] [98] [99]

DRL kombinuje funkci vnímání metody Deep Learning se schopností rozhodování metody Reinforcement Learning. Je to metoda umělé inteligence, která je blíží lidskému myšlení a je považována za skutečnou umělou inteligenci. Aplikační rámec (z anglického Framework) metody DRL je zobrazen v Obr.8) [97]

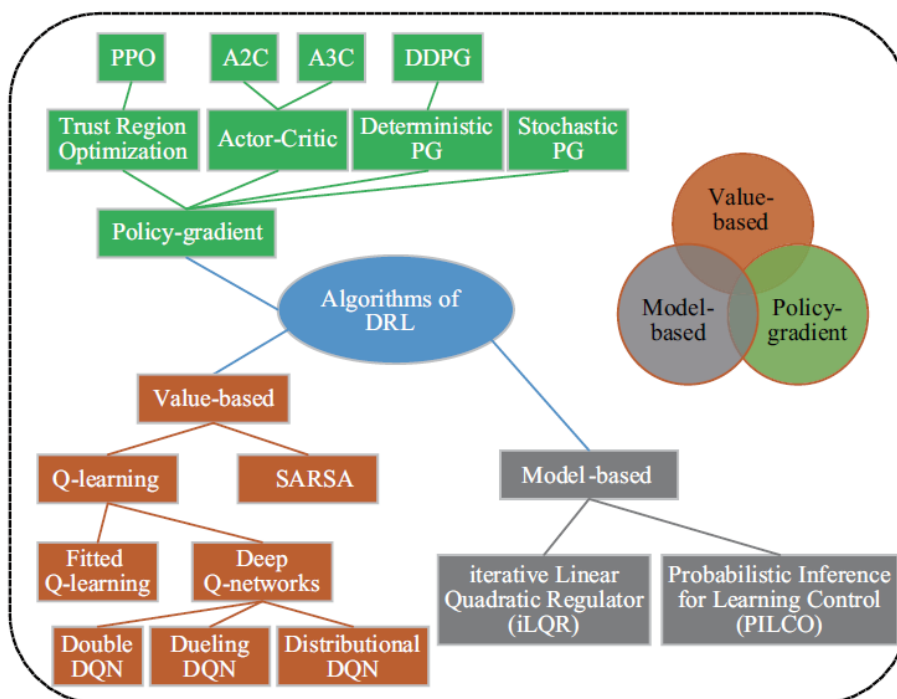


Obr.8) Framework metody Deep Reinforcement Learning [97]

Metoda Deep Learning získává informace o cílovém pozorování z prostředí a informace o stavu v současném prostředí. Reinforcement Learning poté mapuje aktuální stav na odpovídající akci a vyhodnocuje hodnoty na základě zpětné odezvy. Kontinuální interakční proces vytváří rozhodovací chování krok za krokem. [97] [100] [101]

### DRL algoritmy

DRL problémy lze formulovat jako problémy optimalizační, plánovací, správní a kontrolní. Metody řešení mohou být model-free, tedy bez modelu, nebo model-based, tedy založené na modelu, value-based, tedy založené na hodnotách anebo policy-based, tedy založené na pravidlech, jak je znázorněno v Obr.9). Model-based DRL je silně ovlivněno teorií řízení a často je vysvětleno v souvislosti s jinými disciplínami. Na rozdíl od toho model-free ignoruje model a méně se zaměřuje na vnitřní fungování. Výhodou DRL založeného na modelu je to, že je jednoduchý a účinný. Na příklad, pokud je vhodné aproximovat prostor jako lineární, naučit se model bude vyžadovat mnohem méně příkladů. Nicméně, metody model-based jsou o několik řádů složitější, než metody model-free. Pokud jde o vzorkování provádět pomocí počítačové simulace, metody model-free zaberou mnohem méně času. Pro zjednodušení výpočtu mají metody založené na modelu také více předpokladů a aproximací, a proto se mohou omezit na konkrétní typy úkolů. Většina metod policy-based a value-based jsou bez modelu. [97]



Obr.9) Hlavní algoritmy metody DRL a jejich vzájemné vztahy [97]

### 3.7.1 Energetické řízení

V energetické soustavě, zejména v mikro sítích, se problémy s energetickým řízením spojují se zdroji, zátěží, úložným systémem a rozvodnými sítěmi. Energetické řízení hraje zásadní roli několika způsoby. Za prvé, může zlepšit míru využití obnovitelné energie a řídit spotřebu domácích spotřebičů. Kromě toho může plánovat strategii ukládání energie a reagovat na ceny elektřiny v reálném čase. Zajímavé z pohledu umělé inteligence je, že většinu problémů s řízením energie lze transformovat do postupných rozhodovacích problémů a lze je efektivně řešit pomocí DRL. [97]

Domácí spotřebiče potřebují optimální strategie řízení energie, což je přesně to, co DRL skvěle zvládá. Některé předešlé studie navrhují použití metody DRL při navrhování online optimalizace pro rozvržení spotřeby elektřiny rezidenčních oblastech a jim přilehlých aglomeracích. Tuto strategii řízení lze použít k poskytování zpětné vazby zákazníkům v reálném čase, aby mohli elektřinu využívat efektivněji. Optimální strategie založená na DRL je navržena tak, aby se minimalizovaly celkové náklady na elektřinu při případných problémech s řízením energie v domácnosti, a to bez znalosti současné zátěže domácnosti vůči soustavě a bez znalosti ceny elektřiny. V předchozí studii byl například postaven domovní Multi-Carrier Energy System (MCES) zahrnující fotovoltaické panely, baterie, tepelné čerpadlo a plynový kotel a používající metody DRL k vývoji strategie řízení pomocí skutečných dat pro plánování optimálního rozvržení baterií. [102] [103] [104]

Další uplatnění DRL je při řešení problémů s energetickým řízením elektrických vozidel, jež v posledních letech rychle přibývala a upoutala pozornost vývojářů metody DRL. Pro maximalizování ekonomičnosti spotřeby energie v určitém časovém horizontu a udržení stabilního stavu nabití baterie u elektrických vozidel založeného na strategii řízení energie pomocí metody Deep Q-Learning (DQL) je navrženo v další studii, kde DQL ukázala lepší výkonnost, než Q-Learning za danou dobu tréninku a míru konvergence. Podobně tomu, další studie navrhuje model-free DRL přístup k určení optimální strategie pro plánování nabíjení/vybíjení elektrických vozidel v reálném čase bez informací o modelu systému. V další studii byla vyvinuta Metoda DRL založená na daty řízeném přístupu, která má architekturu učení v reálném čase pro hybridní elektrické vozidlo bez jakýchkoliv predikcí nebo předdefinovaných pravidel. Z větší části dosahuje podstatných úspor energie ve srovnání s tradičními metodami řízení. V další studii autoři navrhli strategii nepřetržitého řízení pro Plug-in hybridní elektrické vozidlo na základě Deep Deterministic Policy Gradient (DDPG) a algoritmus vykazuje výkon blízký globálnímu optimu pro dynamické programování. [105] [106] [107] [108] [109]

Metoda DRL má mnoho výhod při řešení problému oproti tradičním metodám:

- DRL může dosáhnou online optimalizace stejně jako kontroly v reálném čase a zpětné vazby řízení energie;
- DRL může zvýšit efektivitu využití energie, snížit provozní náklady a zvýšit zisky;
- DRL dokáže zvládnou kompilované úkoly s menšími předchozími znalostmi díky její schopnosti naučit se různé úrovně abstrakce z dat. [97]

Nicméně, řízení energie má pořád mnoho problémů, jako jsou:

- výroba větrné a solární energie má velké výkyvy mnoho nejistot;
- různé systémy skladování energie mají různé generace, kapacitu, efektivitu a náklady, takže koordinovaná kontrola je obtížná;
- úroveň nabíjení a vybíjení elektrických vozidel a domácích spotřebičů je náhodná a informace o ní jsou nekompletní;
- systém energetického řízení komunikuje s různými energetickými oběhy včetně těch, které slouží k výrobě energie, přenosu, distribuci atd. [97]

Vzhledem k výše uvedeným problémům by se metoda DRL měla zaměřit na následující:

- transformace problémů v reálném světě do sekvenčních rozhodovacích problémů na základě předešlých dat a fyzických modelů;

- vytváření vhodných přednostních funkcí v souladu s cíli a podmínkami omezení skutečných problémů;
- zvážení klasických modelů a metod při použití dat řízených technik. [97]

### 3.7.2 Reakce na poptávku

Reakce na poptávku je typický problém v inteligentní síti, která udržuje rovnováhu mezi poptávkou zákazníků po elektřině a dodávkou elektřiny energetickými společnostmi podle ceny. Pro zlepšení stability sítě a vyrovnání poptávky po elektrické energii ve špičce musí reakce na poptávku zahrnovat zpětnou vazbu zákazníka a spotřeby v regulační smyčce. Metoda DRL je tedy efektivní a optimální přístup k řízení pomocí dat řízených podpůrných modelů pro řešení problému. [110] [111]

V případě spotřebitelů elektrické energie je hlavním cílem minimalizace nákladů a maximalizování zisku. Za účelem vyřešení problému reakce na poptávku založeného na řízení v reálném čase, je navržen přístup DRL s tím, že poskytovateli služeb pomáhá při nákupu elektřiny od různých zákazníků, aby se vyrovnalo kolísání energie a udržovala se spolehlivost sítě. Analogický postup byl proveden ve studii, kde navrhuje DRL přístup pro tvorbu sekvenčních optimálních rozhodnutí na základě poptávky ve vytápěcích, ventilačních a klimatizačních systémech. Optimální a autonomní plánování spotřeby elektřiny v těchto systémech je plánováno multiagentním RL pro minimalizování nákladů. Optimální cenové schéma pro reakci na poptávku založené na metodě RL a rovnováha mezi průzkumem a využíváním v procesech učení vede k lepší výkonnosti energetických společností. Optimální model řešení rezidenčního zatížení pomocí metody RL je uveden v další studii, kde autoři berou v úvahu spokojenost zákazníka, zdroje obnovitelné energie a náklady. Kromě toho lze model udělat obecnějším. Další studie na toto téma navrhuje nový přístup reakce na poptávku ke snížení dlouhodobých nabíjecích/vybíjecích nákladů plug-in elektrických vozidel pomocí metod RL a Bayesian Neural Network. [112] [113] [114] [115] [116] [117]

Z informací uvedených výše je zřejmé, že DRL má následující výhody:

- DRL může dělat rozhodnutí na základě neúplných informací a taková rozhodnutí mohou být online;
- prostřednictvím modelu teorie her může DRL dosáhnout maximálních systémových výhod a snížit transakční náklady;
- DRL mají silnější přenosovou schopnost a lze je použít na mnoho různých aplikací. [97]

Současně se výzvy v oblasti reakce na poptávku odrážejí v následujících aspektech:

- podnětná opatření mají různou formu a zahrnují ekonomické, technologické, enviromentální a politické iniciativy (různí uživatelé reagují na pobídky odlišně);
- reakce na poptávku je obvykle doprovázena změnami v různých faktorech, jako jsou cena elektřiny a různé faktory mění výsledky odlišně;
- metody řízení a omezující podmínky elektrického zařízení zapojeného do odezvy, což komplikuje model. [97]

K překonání výše uvedených problémů se musí DRL přístupy zvážit z následujících pohledů:

- využití DNN a dalších metod k extrahování charakteristik chování spotřebitelů a predikování jejich chování jako základ optimální kontroly;

- výběr vhodného stavového prostoru, včetně ceny, zatížení, úložných systémů energie a tak dále;
- plné využití předchozích dat a zpětné vazby od spotřebitelů pro vyrovnání nedostatku modelů. [97]

### 3.7.3 Trh s elektřinou

Hierarchii trhu s elektřinou lze rozdělit na velkoobchodní trh a maloobchodní trh. Ty spojují poskytovatele služeb s energetickými společnostmi a zákazníky s informacemi a energiemi. Velkoobchodní trh je tvořen konkurenčními energetickými společnostmi nabízejícími svou elektřinu maloobchodníkům, kteří ji poté prodávají poskytovatelům služeb. Mimo to, maloobchodní trh je tvořen zákazníky, kteří si vybírají své dodavatele od konkurenčních maloobchodníků. Obchodování mezi těmito dvěma kategoriemi je složitý problém a DRL lze použít k získání optimálních strategií z neúplných informací. [97]

Aplikace metody DRL v této oblasti, má oproti běžným metodám následující silné stránky:

- většina algoritmů DRL je bez modelu a jsou vhodné pro případy, které nelze formulovat do modelů;
- aproximátory funkcí, jako jsou ANNs, mohou extrahovat více datových vlastností, které modely neberou v úvahu;
- lze s nimi dosáhnout rovnováhy mezi stranami nabídky a poptávky na trzích s elektřinou. [97]

Na druhou stranu, trh s elektřinou má tyto hlavní problémy:

- na hierarchickém trhu s elektřinou existuje více subjektů a jejich cíle jsou odlišné, což ztěžuje tvorbu přednostních funkcí;
- kromě toku energie existují mezi jednotlivými entitami také neúplné informace, takže jsou zapotřebí daty řízené metody;
- obchodování s energií je nepřetržitý rozhodovací problém, na rozdíl od typických diskrétních rozhodovacích problémů a vyžaduje rozhodování v reálném čase. [97]

S ohledem na tyto problémy by měly následující aspekty být cílem budoucího výzkumu metod DRL:

- použití modelů teorie her k vytvoření různých tržních entit;
- použití multiagentní RL a agentů odpovídajících různým herním entitám;
- zlepšování schopnosti integrovat a extrahovat informace, jako je cena a energie. [97]

## 4 ZHODNOCENÍ A DISKUZE

Implementace různých algoritmů strojového učení do konvenčních i nekonvenčních obráběcích procesů z důvodu diagnostiky a prognostiky v oblasti obráběcích strojů, optimalizace parametrů a predikce kvality obrobku vede k výrobě s vyšší nákladovou efektivitou. Lze pozorovat, že nejčastěji používanými metodami byly SVM a ANN, a právě ty dosáhly nejlepších výsledků. Výsledky aplikací jednotlivých metod na daný proces obrábění shrnuje Tab 1). Ačkoliv tyto metody obecně vykazují skvělé výsledky, jejich přesnost bude výrazně záviset na použitých vstupních parametrech získaných při předzpracování dat a pomocí metod extrakce prvků. Pro praktické použití bude rozhodující další výzkum zaměřený na tyto techniky extrakce prvků. ANN a SVR byly také použity pro zlepšení stavby stroje, tepelných a dynamických charakteristik. Autoři však neposkytnou dostatek informací o výkonu algoritmů. [7]

Tab 1) Výsledky aplikací metod strojového učení na metody obrábění [7]

Metoda	Účel	Algoritmus	Vstupní parametry	Předzpracování dat	Přesnost	Rok Zdroj
Frézování	Sledování opotřebení nástroje	K-NN, SVM	Snímky nástroje	Deskriptory tvaru a obrysu	90,26 %	2017 [24]
	Predikce opotřebení nástroje	RF	Řezná síla, vibrace, akustické emise	Statistické funkce (max, medián)	90,20 %	2017 [25]
	Detekce zlomení nástroje	SVM, SVR	Řezná síla a data spotřeby energie	/	99,38 %	2005 [26]
		PNN	Otáčky vřetena, rychlost posuvu, hloubka záběru, max. řezná síla	/	98,60 %	2015 [16]
	Predikce spotřeby energie	Gaussův proces regrese	Otáčky vřetena, rychlost posuvu, hloubka záběru, aktivní osa nástroje	/	Přes 95 %	2015 [27]
	Predikce drsnosti povrchu	SVM	Otáčky vřetena, rychlost posuvu, hloubka záběru	Normalizace	86,50 %	2016 [12]
	Predikce stability chvění	SVM	Vibrační signály (řezná síla v ose x a směr v ose y)	Vlnková paketová transformace	98,33 %	2015 [28]
	Určení specifické řezné síly	BpNN	Řezný materiál, potahování nástroje, řezná rychlost, rychlost posuvu	/	87,44 %	2017 [29]
	Predikce deformací v tenkostěnném prvku	Bayesovská metoda učení	Informace o předchozích deformacích	/	/	2017 [30]

Soustružení	Predikce drsnosti povrchu	MLR	Řezná rychlost, posuv, hloubka záběru, opotřebení boku nástroje, vibrace	Statistické funkce (standartní odchylka, medián), PCA	80,80 %	2015 [33]
	Predikce parametrů obrábění (Drsnost povrchu, řezná síla atd.)	SVR, ANNs	Řezná rychlost, posuv, hloubka záběru	Regularizace	Okolo 93 %	2016 [34]
	Predikce mikrotvrdosti a velikosti zrna	RF, GA	Řezná rychlost, posuv, radius špičky nástroje, povlakování řezného nástroje	/	96,50 %	2015 [19]
	Predikce a kvantifikace emisí uhlíku, optimalizace řezných parametrů	MOTLBO	Řezná rychlost, posuv, hloubka záběru	Grey relational analysis (GRA)	Okolo 95 %	2015 [32]
	Predikce opotřebení nástroje a rozpoznání vzorku	BpNN, DNA-based computing	Obráběcí čas, řezná rychlost, posuv, hloubka záběru	Zpracování obrazu, binární obrazový data	75 %	2017 [35]
	Sledování nástrojových podmínek	K-Star algoritm	Vibrační signály	Statistické funkce (Standartní chyba a odchylka atd.)	78,69 %	2014 [36]
Broušení	Sledování drsnosti a tvaru povrchu	IFSVR	Akustické emise, řezná síla, vibrace	Identifikační model, Rychlá Fourierova transformace	85,19 % (Ra) 75,93 % (PV)	2015 [37]
Vrtání	Ověřování kvality a geometrického povrchu (kruhovitost, rozměrové odchylky atd.)	LAoD	Řezná síla, Točivý moment	/	94,60 %	2015 [38]
Vyvrtávání	Predikce chvění	SVM	Otáčky vřetene, hloubka záběru, Posuv	Diskrétní vlnková transformace	95 %	2017 [39]
Řezání laserem	Predikce kvality obrobeného povrchu, rozměrových vlastností a míry produktivity	ANN, DT, K-NN, Linear Regression	Rychlost ohřevu materiálu, intenzita laseru, frekvence laseru	/	88,70 % (NN) 76,90 % (DT)	2015 [40]

Řezání vodním paprskem	Predikce drsnosti povrchu	Extreme machine learning, ANN, GPR	Řezná rychlost, tloušťka materiálu, tok abraziva	/	96,65 %	2016 [42]
		SVM	Rychlost posuvu, tlak vodního paprsku, velikost zrn abraziva	GRA	99 %	2013 [41]
		BpNN, Regression model	Rychlost posuvu, tlak vodního paprsku, vzdálenost trysky od materiálu, velikost zrn abraziva	/	96,99 % (NN) 99 % (model)	2008 [43]
Elektroerozivní obrábění	Odhad max. řez. rychlosti a optimalizace parametrů obrábění	BpNN, GA	Velikost pracovní mezery, kapacita, rychlost posuvu	/	96,06 %	2010 [45]
Elektrochemické obrábění	Optimalizace procesních parametrů	TLBO	Koncentrace elektrolytu, průtok elektrolytu, přivedené napětí	/	Zlepšení o 18 %	2011 [46]

V oblasti návrhu produktu mohou techniky umělé inteligence pomoci konstruktérům při výběru nejvhodnějších materiálů pro konkrétní průmyslovou aplikaci. Přestože metody Supervised Learning vyžadují předběžný výcvik a obecně jsou výpočetně náročnější, lze s nimi dosáhnout komplexnějších výsledků. Algoritmy umělé inteligence lze použít k extrahování informací z rozsáhlých datových souborů, které je obtížné spravovat pomocí tradičních technik. Neural Networks jsou techniky schopné naučit se nelineární funkce. Metody Unsupervised Learning dosahují méně přesných výsledků, ale mohou sloužit jako nástroj k předzpracování souboru dat před provedením složitějšího zpracování. [49]

Technologie umělé inteligence nejen pomáhají snižovat pracovní zátěž zaměstnanců a snižují využití materiálních zdrojů v oblasti automatizačního řízení, ale také zkracují čas operací, snižují výrobní náklady podniků a zlepšují celkovou efektivitu výroby. V dnešní době existuje mnoho oblastí použití technologií umělé inteligence v procesu automatizace, jako je diagnostika poruch, elektrická zařízení, zjednodušení procesu, elektronické ovládání, každodenní provoz atd. Každý proces se stal mnohem jednodušší a úroveň automatizačního řízení se v naší zemi neustále vyvíjí. Využití technologií umělé inteligence učinilo z automatizačního řízení oblast se slibným vývojem a s velkým potenciálem do budoucna. [73]

Techniky Machine learning mohou být použity a aplikovány ve výrobním procesu oceli, který se spoléhá na monitorovací technologie, jako je detekce vad, za účelem snížení počtu výrobních chyb, které mohou vést k velkým ztrátám. Investice do algoritmů ML, mohou být použity s cílem vylepšení diagnostiky poruch, jejíž výsledky pomáhají při přesném



rozhodování. Budoucí výzkum se bude zaměřovat na vyhodnocování technik diagnostiky poruch v reálném čase pomocí prediktivní údržby. Výzkumu je naprosto zásadní, protože senzory zaznamenávají obrovské množství dat, která vyžadují Big data analýzu pro lepší rozhodování. Monitorování výrobního procesu v reálném čase je doposud omezeno kvůli chybějícím vhodným monitorovacím technikám pro identifikaci chyb. [76]

V oblasti energetiky umí metody DRL řešit problémy ve velkých a rozměrných systémech. S dalším výzkumem a vývojem inteligentních sítí se energetické systémy vyvíjejí a čelí novým výzvám spojeným s obnovitelnou energií. Tradiční metody čelí mnoha potížím při řešení těchto problémů v energetických systémech, takže vzniká stále větší potřeba metod umělé inteligence, jako je DRL. [97]

Přes své úspěšné modely a aplikace, DRL stále čelí problémům a výzvám, pokud jde o implementaci v reálném světě. To je zejména případ energetických systémů, kde je stále mnoho problémů, které je třeba vyřešit. Ku příkladu, hra Go, na niž byly úspěšně aplikovány metody umělé inteligence, má přísná pravidla a návratnost každé akce lze přesně spočítat a vyhodnotit. Avšak, ve srovnání s hrou Go je energetický systém komplikovanější a má mnoho neznámých. Například výrobu obnovitelné energie nelze popsat a predikovat pomocí přesných modelů. S ohledem na výše uvedenou situaci vyžaduje DRL několik změn a úprav, aby se přizpůsobily více aplikacím. Za prvé, přednostní funkce musí být navržena na praktické problémy a na určování směru a účinnosti učení. Za druhé, funkční aproximátory je třeba pečlivě vybírat, zejména na komplikované úkoly. A na závěr, kompromis mezi průzkumem a využitím nelze ignorovat, proto je třeba provést inicializaci a parametry pečlivě nastavit. [97]

Závěrem lze říct, že metoda DRL a její aplikace na energetickou přenosovou soustavu čelí stále mnoha příležitostem a výzvám. To s největší pravděpodobností způsobí větší pozornost a širší výzkum v této oblasti, čímž v budoucnu jistě nevyhnutelně dojde k rychlejšímu vývoji. [97]



## 5 ZÁVĚR

Cílem této práce bylo vytvořit přehled použití metod umělé inteligence v praktických aplikacích v souladu s konceptem průmyslu 4.0 a z důvodu většího záběru v oblasti umělé inteligence byla věnována pozornost několika používaným metodám umělé inteligence, které byly náležitě popsány a zhodnoceny z pohledu jejich předností, úskalí a budoucího využití v konkrétních oblastech aplikace.

V některých kapitolách může docházet ke složitějšímu porozumění danému tématu z důvodu použití anglických zdrojů. Vzhledem k faktu, že některé anglické pojmy nemají přesný český překlad je většina názvů metod umělé inteligence, jejich algoritmů a nástrojů zmiňována v anglickém originále. Ovšem co se týče samotného textového obsahu, myšlenek a názorových proudů, vychází z nejnovějších studií uznávaných světových odborníků v daném oboru.

Umělá inteligence má v konceptu průmyslu 4.0 nezastupitelné místo a její potenciál v budoucích praktických aplikacích je obrovský. Pevně věřím, že tato práce poslouží jako vhodný materiál pro závěrečné práce na toto téma v budoucnu a následujícímu vývoji nástrojů průmyslu 4.0, které se již brzy dostanou do praxe v hromadném měřítku.

## 6 SEZNAM POUŽITÝCH ZDROJŮ

- [1] MAŘÍK, Vladimír. *Průmysl 4.0*. Vydání 1. Management Press, 262 s. ISBN 978-80-7261-440-0.
- [2] BAHRIN, Mohd, Fauzi OTHMAN, Nor AZLI a Muhamad TALIB. Industry 4.0: A review on industrial automation and robotic. *Jurnal Teknologi*. 2016, **78**. DOI: 10.11113/jt.v78.9285.
- [3] CEJNAROVÁ, Andrea. *Od 1. průmyslové revoluce ke 4.* [online]. In: . [cit. 2020-06-03]. Dostupné z: [https://www.technickydenik.cz/rubriky/ekonomika-byznys/od-1-prumyslove-revoluce-ke-4\\_31001.html](https://www.technickydenik.cz/rubriky/ekonomika-byznys/od-1-prumyslove-revoluce-ke-4_31001.html)
- [4] MATHAS, Carolyn. Industry 4.0 is closer than you think. In: *EDN Network* [online]. Cambridge, MA, USA: AspenCore, Inc., 2020 [cit. 2020-06-23]. Dostupné z: <https://www.edn.com/industry-4-0-is-closer-than-you-think/>
- [5] LEE, Jay, Hossein DAVARI, Jaskaran SINGH a Vibhor PANDHARE. Industrial Artificial Intelligence for industry 4.0-based manufacturing systems. *Manufacturing Letters*. 2018, **18**, 20-23. DOI: <https://doi.org/10.1016/j.mfglet.2018.09.002>. ISSN 2213-8463. Dostupné z: <http://www.sciencedirect.com/science/article/pii/S2213846318301081>
- [6] LEE, Jay, Jaskaran SINGH a Moslem AZAMFAR. *Industrial AI: is it manufacturing's guiding light?*. 2019, **20**, 26-36. DOI: 10.7945/tt9s-gz25.
- [7] KIM, Dong-Hyeon, Thomas KIM, Xinlin WANG et al. Smart Machining Process Using Machine Learning: A Review and Perspective on Machining Industry. *International Journal of Precision Engineering and Manufacturing-Green Technology*. 2018, **5**, 555-568. DOI: 10.1007/s40684-018-0057-y.
- [8] VAHABLI, Ebrahim a Sadegh RAHMATI. Application of an RBF neural network for FDM parts' surface roughness prediction for enhancing surface quality. *International Journal of Precision Engineering and Manufacturing*. 2016, **17**, 1589-1603. DOI: 10.1007/s12541-016-0185-7.
- [9] SCHMIDHUBER, Jürgen. Deep learning in neural networks: An overview. *Neural Networks*. 2015, **61**, 85-117. DOI: <https://doi.org/10.1016/j.neunet.2014.09.003>. ISSN 0893-6080. Dostupné z: <http://www.sciencedirect.com/science/article/pii/S0893608014002135>
- [10] CHO, S. a S. KANG. Industrial applications of machine learning (artificial intelligence). *IE Magazine*. **2016**(2), 34-38, 23 s.
- [11] WUEST, Thorsten, Chris IRGENS a Klaus-Dieter THOBEN. An approach to quality monitoring in manufacturing using supervised machine learning on product state data. *Journal of Intelligent Manufacturing*. 2014, **25**(5), 1167-1180. DOI: 10.1007/s10845-013-0761-y.
- [12] LU, Xiaohong, Xiaochen HU, Hua WANG, Likun SI, Yongyun LIU a Lusi GAO. Research on the prediction model of micro-milling surface roughness of Inconel718

- based on SVM. *Industrial Lubrication and Tribology*. 2016, **68**(2), 206-211. DOI: 10.1108/ILT-06-2015-0079.
- [13] JIA, Feng, Yaguo LEI, Jing LIN, Xin ZHOU a Na LU. Deep neural networks: A promising tool for fault characteristic mining and intelligent diagnosis of rotating machinery with massive data. *Mechanical Systems and Signal Processing*. 2015, **72-73**. DOI: 10.1016/j.ymsp.2015.10.025.
- [14] TAN, Shing, Junzo WATADA, Zuwairie IBRAHIM a Marzuki KHALID. Evolutionary Fuzzy ARTMAP Neural Networks for Classification of Semiconductor Defects. *IEEE transactions on neural networks and learning systems*. 2014, **26**(5). DOI: 10.1109/TNNLS.2014.2329097.
- [15] PONTES, Fabrício, Anderson PAIVA, Pedro BALESTRASSI, João FERREIRA a Messias SILVA. Optimization of Radial Basis Function neural network employed for prediction of surface roughness in hard turning process using Taguchi's orthogonal arrays. *Expert Systems with Applications*. 2012, **39**(9), 7776-7787. DOI: <https://doi.org/10.1016/j.eswa.2012.01.058>. ISSN 0957-4174. Dostupné z: <http://www.sciencedirect.com/science/article/pii/S0957417412000711>
- [16] HUANG, PoTsang, Cheng-Chieh MA a Chia-Hao KUO. A PNN self-learning tool breakage detection system in end milling operations. *Applied Soft Computing*. 2015, **37**, 114-124. DOI: <https://doi.org/10.1016/j.asoc.2015.08.019>. ISSN 1568-4946. Dostupné z: <http://www.sciencedirect.com/science/article/pii/S1568494615005177>
- [17] LE, Kelvin, Chee PANG, Oon GAN, Xiang CHEE, Dan ZHANG, Ming LUO, Hian CHAN a Frank LEWIS. Classification of energy consumption patterns for energy audit and machine scheduling in industrial manufacturing systems. *Transactions of the Institute of Measurement and Control*. 2013, **35**(5), 583-592. DOI: 10.1177/0142331212460883.
- [18] PONTES, Fabrício, João FERREIRA, Messias SILVA, Anderson PAIVA a Pedro BALESTRASSI. Artificial neural networks for machining processes surface roughness modeling. *The International Journal of Advanced Manufacturing Technology*. 2010, **49**(9), 879-902. DOI: 10.1007/s00170-009-2456-2. ISSN 1433-3015. Dostupné z: <https://doi.org/10.1007/s00170-009-2456-2>
- [19] ARISOY, Yiğit a Tuğrul ÖZEL. Machine Learning Based Predictive Modeling of Machining Induced Microhardness and Grain Size in Ti-6Al-4V Alloy. *Materials and Manufacturing Processes*. Taylor & Francis, 2015, **30**(4), 425-433. DOI: 10.1080/10426914.2014.961476. ISSN 1042-6914. Dostupné z: <https://doi.org/10.1080/10426914.2014.961476>
- [20] YUAN, Jin, Kesheng WANG, zhantao YU a Minglun FANG. Reliable multi-objective optimization of high-speed WEDM process based on Gaussian process regression. *International Journal of Machine Tools and Manufacture*. 2008, **48**(1), 47-60. DOI: 10.1016/j.ijmachtools.2007.07.011.
- [21] KUPP, N., K. HUANG, J. CARULLI a Y. MAKRIS. Spatial estimation of wafer measurement parameters using Gaussian process models. In: *2012 IEEE*

*International Test Conference*. Anaheim, CA, USA: IEEE, 2012, s. 1-8. DOI: 10.1109/TEST.2012.6401545. ISBN 978-1-4673-1595-1. ISSN 2378-2250.

- [22] DEB, Kalyan, Amrit PRATAP, Sameer AGARWAL a T. MEYARIVAN. A fast and elitist multiobjective genetic algorithm: NSGA-II. *IEEE Transactions on Evolutionary Computation*. IEEE, 2002, **6**(2), 182-197. DOI: 10.1109/4235.996017. ISSN 1089-778X.
- [23] SU, Ming-Shou, Chung-Chu CHIA, Chien-Yi CHEN a J.F. CHEN. Classification of partial discharge events in GILBS using probabilistic neural networks and the fuzzy c-means clustering approach. *International Journal of Electrical Power & Energy Systems*. 2014, **61**, 173–179. DOI: 10.1016/j.ijepes.2014.03.054.
- [24] GARCÍA-ORDÁS, M. *Wear Characterization of the Cutting Tool in Milling Processes Using Shape and Texture Descriptors*. León, 2017, 195 s. Dostupné z: <https://dialnet.unirioja.es/servlet/tesis?codigo=124327>. Disertace. Universidad de León. Vedoucí práce Enrique Alegre Gutiérrez.
- [25] WU, Dazhong, Connor JENNINGS, Janis TERPENNY, Robert GAO a Soundar KUMARA. A Comparative Study on Machine Learning Algorithms for Smart Manufacturing: Tool Wear Prediction Using Random Forests. *Journal of Manufacturing Science and Engineering*. 2017, **139**(7).
- [26] CHO, Sohyung, Shihab ASFOUR, Arzu ONAR-THOMAS a Nandita KAUNDINYA. Tool breakage detection using support vector machine learning in a milling process. *International Journal of Machine Tools and Manufacture*. 2005, **45**(3), 241-249. DOI: 10.1016/j.ijmachtools.2004.08.016.
- [27] PARK, Jinkyoo, Kincho LAW, Raunak BHINGE, Nishant BISWAS, Amrita SRINIVASAN, David DORNFELD, Moneer HELU a Sudarsan RACHURI. *A Generalized Data-Driven Energy Prediction Model With Uncertainty for a Milling Machine Tool Using Gaussian Process*. Charlotte, NC, USA, 2015. DOI: 10.1115/MSEC2015-9354. Dostupné z: [https://www.researchgate.net/publication/286418365\\_A\\_Generalized\\_Data-Driven\\_Energy\\_Prediction\\_Model\\_With\\_Uncertainty\\_for\\_a\\_Milling\\_Machine\\_Tool\\_Using\\_Gaussian\\_Process](https://www.researchgate.net/publication/286418365_A_Generalized_Data-Driven_Energy_Prediction_Model_With_Uncertainty_for_a_Milling_Machine_Tool_Using_Gaussian_Process)
- [28] PENG, Chong, Lun WANG a T. LIAO. A new method for the prediction of chatter stability lobes based on dynamic cutting force simulation model and support vector machine. *Journal of Sound and Vibration*. 2015, **354**, 118-131. DOI: 10.1016/j.jsv.2015.06.011.
- [29] ARNOLD, F., Albrecht HÄNEL, A. NESTLER a Alexander BROSIUS. New Approaches for the Determination of Specific Values for Process Models in Machining Using Artificial Neural Networks. *Procedia Manufacturing*. 2017, **11**, 1463-1470. DOI: 10.1016/j.promfg.2017.07.277.
- [30] YUAN, Ye, Hai-Tao ZHANG, Yue WU, Tao ZHU a Han DING. Bayesian Learning-Based Model-Predictive Vibration Control for Thin-Walled Workpiece Machining Processes. *IEEE/ASME Transactions on Mechatronics*. 2017, **22**(1), 509-520. DOI: 10.1109/TMECH.2016.2620987.

- [31] BENKEDJOUH, Tarak, Kamal MEDJAHHER, Nouredine ZERHOUNI a Said RECHAK. Health Assessment and Life Prediction of cutting tools based on support vector regression. *Journal of Intelligent Manufacturing*. 2013, **26**(2), 213-223. DOI: 10.1007/s10845-013-0774-6.
- [32] LIN, Wenwen, D.Y. YU, Shaojun WANG, Chaoyong ZHANG, Sanqiang ZHANG, Huiyu TIAN, Min LUO a Shengqiang LIU. Multi-objective teaching-learning-based optimization algorithm for reducing carbon emissions and operation time in turning operations. *Engineering Optimization*. 2014, **47**, 1-14. DOI: 10.1080/0305215X.2014.928818.
- [33] ELANGO VAN, M., N. SAKTHIVEL, S. SARAVANAMURUGAN, Binoy NAIR a V. SUGUMARAN. Machine Learning Approach to the Prediction of Surface Roughness Using Statistical Features of Vibration Signal Acquired in Turning. *Procedia Computer Science*. 2015, **50**, 282-288. DOI: 10.1016/j.procs.2015.04.047.
- [34] JURKOVIC, Zoran, Goran CUKOR, Miran BREZOCNIK a Tomislav BRAJKOVIC. A comparison of machine learning methods for cutting parameters prediction in high speed turning process. *Journal of Intelligent Manufacturing*. 2016, **29**, 1683-1693. DOI: 10.1007/s10845-016-1206-1.
- [35] D'ADDONA, Doriana, Sharif ULLAH a Davide MATARAZZO. Tool-wear prediction and pattern-recognition using artificial neural network and DNA-based computing. *Journal of Intelligent Manufacturing*. 2015, **28**, 1285-1301. DOI: 10.1007/s10845-015-1155-0.
- [36] PAINULI, Sanidhya, M. ELANGO VAN a V. SUGUMARAN. Tool condition monitoring using K-star algorithm. *Expert Systems with Applications*. 2014, **41**(6), 2638–2643. DOI: 10.1016/j.eswa.2013.11.005.
- [37] ZHANG, Dongxu, Guo BI, Zhiji SUN a Yinbiao GUO. Online monitoring of precision optics grinding using acoustic emission based on support vector machine. *The International Journal of Advanced Manufacturing Technology*. 2015, **80**(5), 761-774. DOI: 10.1007/s00170-015-7029-y.
- [38] SHABAN, Y., S. YACOUT, M. BALAZINSKI, M. MESHREKI a H. ATTIA. Diagnosis of machining outcomes based on machine learning with Logical Analysis of Data. In: *2015 International Conference on Industrial Engineering and Operations Management (IEOM)*. Dubai, United Arab Emirates: IEEE, 2015, s. 1-8. DOI: 10.1109/IEOM.2015.7093752. ISBN 978-1-4799-6065-1.
- [39] SARAVANAMURUGAN, S., S. THIYAGU, N. SAKTHIVEL a Binoy NAIR. Chatter prediction in boring process using machine learning technique. *International Journal of Manufacturing Research*. 2017, **12**(4), 405. DOI: 10.1504/IJMR.2017.088399.
- [40] TEIXIDOR, Daniel, Maciej GRZENDA, Andrés BUSTILLO a Joaquim CIURANA. Modeling pulsed laser micromachining of micro geometries using machine-learning techniques. *Journal of Intelligent Manufacturing*. 2013, **26**(4), 801-814. DOI: 10.1007/s10845-013-0835-x.

- [41] DERIS, Ashanira, Azlan ZAIN a Roselina SALLEHUDDIN. Hybrid GR-SVM for prediction of surface roughness in abrasive water jet machining. *Meccanica*. 2013, **48**(8), 1937-1945. DOI: 10.1007/s11012-013-9710-2.
- [42] COJBASIC, Zarko, Dalibor PETKOVIĆ, Shahaboddin SHAMSHIRBAND, Wen CHONG, Dr. CHINTALAPATI, Predrag JANKOVIĆ, Nedeljko DUCIC a Jelena BARALIĆ. Surface roughness prediction by extreme learning machine constructed with abrasive water jet. *Precision Engineering*. 2015, **43**. DOI: 10.1016/j.precisioneng.2015.06.013.
- [43] ÇAYDAŞ, Ulaş a Ahmet HASÇALIĞ. A study on surface roughness in abrasive waterjet machining process using artificial neural networks and regression analysis method. *Journal of Materials Processing Technology*. 2008, **202**(1), 574-582. DOI: 10.1016/j.jmatprotec.2007.10.024.
- [44] PANDA, Biranchi, M BAHUBALENDRUNI a Bibhuti BISWAL. A general regression neural network approach for the evaluation of compressive strength of FDM prototypes. *Neural Computing and Applications*. 2014, **26**(5), 1129-1136. DOI: 10.1007/s00521-014-1788-5.
- [45] SOMASHEKHAR, K., Ramachandran NOTTATH a Jose MATHEW. Optimization of Material Removal Rate in Micro-EDM Using Artificial Neural Network and Genetic Algorithms. *Materials and Manufacturing Processes - MATER MANUF PROCESS*. 2010, **25**(6), 467-475. DOI: 10.1080/10426910903365760.
- [46] PAWAR, Piyush a Ravipudi VENKATA RAO. Parameter optimization of machining processes using teaching–learning-based optimization algorithm. *The International Journal of Advanced Manufacturing Technology*. 2013, **67**(5), 995-1006. DOI: 10.1007/s00170-012-4524-2.
- [47] MIAO, En-Ming, Ya-Yun GONG, Peng-Cheng NIU, Chang-Zhu JI a Hai-Dong CHEN. Robustness of thermal error compensation modeling models of CNC machine tools. *The International Journal of Advanced Manufacturing Technology*. 2013, **69**(9), 2593-2603. DOI: 10.1007/s00170-013-5229-x. ISSN 1433-3015. Dostupné z: <https://doi.org/10.1007/s00170-013-5229-x>
- [48] PARK, Hong-Seok a Ngoc-Hien TRAN. Development of a smart machining system using self-optimizing control. *The International Journal of Advanced Manufacturing Technology*. 2014, **74**, 1365-1380. DOI: 10.1007/s00170-014-6076-0.
- [49] MERAYO, David, Álvaro RODRÍGUEZ-PRIETO a Ana CAMACHO. *Comparative analysis of artificial intelligence techniques for material selection applied to manufacturing in Industry 4.0*. 2019, **41**, 42-49. DOI: 10.1016/j.promfg.2019.07.027.
- [50] MERAYO, David, Álvaro RODRÍGUEZ-PRIETO a Ana CAMACHO. Analytical and numerical study for selecting polymeric matrix composites intended to nuclear applications. *Proceedings of the Institution of Mechanical Engineers, Part L: Journal of Materials: Design and Applications*. SAGE Publications, 2018, **233**(10), 2072-2083. DOI: 10.1177/1464420718817334. ISSN 1464-4207. Dostupné z: <https://doi.org/10.1177/1464420718817334>



- [51] RODRÍGUEZ-PRIETO, Álvaro, Ana CAMACHO a Miguel SEBASTIÁN. Materials Selection Criteria for Nuclear Power Applications: A Decision Algorithm: A Decision Algorithm. *JOM*. 2016, **68**, 496-506. DOI: 10.1007/s11837-015-1687-y.
- [52] ZHOU, Chang-Chun, Guo-Fu YIN a Xiao-Bing HU. Multi-objective optimization of material selection for sustainable products: Artificial neural networks and genetic algorithm approach. *Materials & Design*. 2009, **30**, 1209-1215. DOI: 10.1016/j.matdes.2008.06.006.
- [53] RAMPRASAD, Rampi, Rohit BATRA, Ghanshyam PILANIA, Arun MANNODI-KANAKKITHODI a Chiho KIM. Machine Learning and Materials Informatics: Recent Applications and Prospects. *Npj Computational Materials*. 2017, **3**. DOI: 10.1038/s41524-017-0056-5.
- [54] TAMBOURATZIS, Tatiana, Dimitris KARALEKAS a Nikolaos G. MOUSTAKAS. A Methodological Study for Optimizing Material Selection in Sustainable Product Design. *Journal of Industrial Ecology*. 2013, **18**. DOI: 10.1111/jieec.12035.
- [55] PAL, Sankar, Saroj MEHER a Andrzej SKOWRON. Data science, big data and granular mining. *Pattern Recognition Letters*. 2015, **67**, 109-112. DOI: <https://doi.org/10.1016/j.patrec.2015.08.001>. ISSN 0167-8655. Dostupné z: <http://www.sciencedirect.com/science/article/pii/S0167865515002561>
- [56] HAFEZALKOTOB, Arian a Ashkan HAFEZALKOTOB. Risk-based material selection process supported on information theory: A case study on industrial gas turbine. *Applied Soft Computing*. 2016. DOI: 10.1016/j.asoc.2016.09.018.
- [57] AKDEMIR, Deniz a Jean-Luc JANNINK. Ensemble learning with trees and rules: Supervised, semi-supervised, unsupervised. *Intelligent Data Analysis*. 2014, **18**, 857-872. DOI: 10.3233/IDA-140672.
- [58] COSTA, Valdigeis, Antonio FARIAS, Benjamin BEDREGAL, Regivan SANTIAGO a Anne CANUTO. Combining multiple algorithms in classifier ensembles using generalized mixture functions. *Neurocomputing*. 2018, **313**, 402-414. DOI: <https://doi.org/10.1016/j.neucom.2018.06.021>. ISSN 0925-2312. Dostupné z: <http://www.sciencedirect.com/science/article/pii/S0925231218307574>
- [59] FAN, Wentao, Faisal AL-OSAIMI, Nizar BOUGUILA a Jixiang DU. Proportional data modeling via entropy-based variational bayes learning of mixture models. *Applied Intelligence*. 2017, **47**(2), 473-487. DOI: 10.1007/s10489-017-0909-0. ISSN 1573-7497. Dostupné z: <https://doi.org/10.1007/s10489-017-0909-0>
- [60] SALZBERG, Steven L. C4.5: Programs for Machine Learning. *Machine Learning*. Baltimore: Morgan Kaufmann Publishers, 1994, **16**(3), 235-240. DOI: 10.1007/BF00993309. ISSN 1573-0565. Dostupné z: <https://doi.org/10.1007/BF00993309>
- [61] HASTIE, Trevor, Robert TIBSHIRANI a Jerome FRIEDMAN. *The Elements of Statistical Learning: Data Mining, Inference, and Prediction (Springer Series in Statistics)*. 2nd edition. New York: Springer-Verlag, 2009. DOI: 10.1007/978-0-387-84858-7. ISBN 0387848576.

- [62] BREIMAN, L., J.H. FRIEDMAN, R.A. OLSHEN a C.J. STONE. *Classification and regression trees*. 2017, 1 s. DOI: 10.1201/9781315139470.
- [63] KIM, Kyoungok. A Hybrid classification algorithm by subspace partitioning through semi-supervised decision tree. *Pattern Recognition*. 2016, **60**. DOI: 10.1016/j.patcog.2016.04.016.
- [64] SCHMIDHUBER, Juergen. Deep Learning in Neural Networks: An Overview. *Neural Networks*. 2014, **61**. DOI: 10.1016/j.neunet.2014.09.003.
- [65] HYVÄRINEN, A a Erkki OJA. Oja, E.: Independent Component Analysis: Algorithms and Applications. *Neural Networks* 13(4-5), 411-430: Independent Component Analysis. *Neural networks: the official journal of the International Neural Network Society*. 2000, **13**, 411-30. DOI: 10.1016/S0893-6080(00)00026-5.
- [66] HUANG, Gao, Guang-Bin HUANG, Shiji SONG a Keyou YOU. Trends in Extreme Learning Machines: A Review. *Neural Networks*. 2014, **61**. DOI: 10.1016/j.neunet.2014.10.001.
- [67] VATTANI, Andrea. K-means Requires Exponentially Many Iterations Even in the Plane. *Discrete & Computational Geometry*. 2009, **45**. DOI: 10.1007/s00454-011-9340-1.
- [68] MAHAJAN, Meena, Prajakta NIMBHORKAR a Rajashekhar KASTURI. *The Planar k-Means Problem is NP-Hard*. 442. 2009, , 274 s. DOI: 10.1007/978-3-642-00202-1\_24.
- [69] HARTIGAN, John A. *Clustering Algorithms*. 99th ed. USA: Wiley, 1975, 351 s. ISBN 978-0-471-35645-5.
- [70] ARTHUR, David a S. VASSILVITSKII. How slow is the k-means method?. *Proceedings of the Annual Symposium on Computational Geometry*. 2006, **2006**, 144-153.
- [71] HOFFMAN, Matthew, David BLEI a Francis BACH. *Online Learning for Latent Dirichlet Allocation*. 23. 2010, , 856 s.
- [72] HOFFMAN, Matthew, David BLEI, Chong WANG a John PAISLEY. Stochastic Variational Inference. *Journal of Machine Learning Research*. Microtome Publishing, 2013, **2013**(1), 1303-1347, 14 s. ISSN 1532-4435.
- [73] YANG, Li. Application of Artificial Intelligence in Electrical Automation Control. *Procedia Computer Science*. 2020, **166**, 292-295. DOI: 10.1016/j.procs.2020.02.097.
- [74] WEI, Sun. Applied Research of Artificial Intelligence Technology in Electrical Automation Control. *Innovation and Application of Science and Technology*. **2014**(7).
- [75] HAO, Chen. Artificial Intelligence Technology in Electrical Automation Control. *Commodity and Quality: Consumption Research*. **2014**(2).
- [76] NKONYANA, Thembinkosi, Yanxia SUN, Bhakisipho TWALA a Eustace DOGO. Performance Evaluation of Data Mining Techniques in Steel Manufacturing

- Industry. *Procedia Manufacturing*. 2019, **35**, 623-628. DOI: <https://doi.org/10.1016/j.promfg.2019.06.004>. ISSN 2351-9789. Dostupné z: <http://www.sciencedirect.com/science/article/pii/S2351978919307292>
- [77] SÁNCHEZ-FERNÁNDEZ, A., F.J. BALDÁN, G.I. SAINZ-PALMERO, J.M. BENÍTEZ a M.J. FUENTE. Fault detection based on time series modeling and multivariate statistical process control. *Chemometrics and Intelligent Laboratory Systems*. 2018, **182**, 57-69. DOI: <https://doi.org/10.1016/j.chemolab.2018.08.003>. ISSN 0169-7439. Dostupné z: <http://www.sciencedirect.com/science/article/pii/S0169743918303459>
- [78] HOU, Zhijian, Zhiwei LIAN, Ye YAO a Xinjian YUAN. Data mining based sensor fault diagnosis and validation for building air conditioning system. *Energy Conversion and Management*. 2006, **47**, 2479-2490. DOI: 10.1016/j.enconman.2005.11.010.
- [79] ESMALIFALAK, Mohammad. A Data Mining Approach for Fault Diagnosis: An Application of Anomaly Detection Algorithm. *Measurement*. 2014.
- [80] LAKSHMI, C., Swagatam DAS a Bijaya PANIGRAHI. *Artificial Intelligence and Evolutionary Computations in Engineering Systems*. 2020. DOI: 10.1007/978-981-15-0199-9. ISBN 978-981-15-0198-2.
- [81] ALDRICH, C. a L. AURET. Fault detection and diagnosis with random forest feature extraction and variable importance methods. *IFAC Proceedings Volumes*. 2010, **43(9)**, 79-86. DOI: <https://doi.org/10.3182/20100802-3-ZA-2014.00020>. ISSN 1474-6670. Dostupné z: <http://www.sciencedirect.com/science/article/pii/S147466701632818X>
- [82] ONEL, Melis, Chris KIESLICH, Yannis GUZMAN a Efstratios PISTIKOPOULOS. Simultaneous Fault Detection and Identification in Continuous Processes via nonlinear Support Vector Machine based Feature Selection. *Computer Aided Chemical Engineering*. 44. 2018, , s. 2077-2082. DOI: 10.1016/B978-0-444-64241-7.50341-4. ISBN 9780444642417.
- [83] ARIYALURAN HABEEB, Riyaz, Fariza NASARUDDIN, Abdullah GANI, Ibrahim HASHEM, Ejaz AHMED a Muhammad IMRAN. Real-time big data processing for anomaly detection: A Survey. *International Journal of Information Management*. 2018. DOI: 10.1016/j.ijinfomgt.2018.08.006.
- [84] JUNG, Marcel, Octavian NICULITA a Zakwan SKAF. Comparison of Different Classification Algorithms for Fault Detection and Fault Isolation in Complex Systems. *Procedia Manufacturing*. 2018, **19**, 111-118. DOI: 10.1016/j.promfg.2018.01.016.
- [85] PUGGINI, Luca, John DOYLE a Sean MCLOONE. Fault Detection using Random Forest Similarity Distance. *IFAC-PapersOnLine*. 2015, **48**, 583-588. DOI: 10.1016/j.ifacol.2015.09.589.

- [86] MAHADEVAN, Sankar a Sirish SHAH. Fault Detection and Diagnosis in Process Data Using One-Class Support Vector Machines. *Journal of Process Control*. 2009, **19**, 1627-1639. DOI: 10.1016/j.jprocont.2009.07.011.
- [87] TUBALLA, Maria a Michael ABUNDO. A review of the development of Smart Grid technologies. *Renewable and Sustainable Energy Reviews*. 2016, **59**, 710-725. DOI: 10.1016/j.rser.2016.01.011.
- [88] HE, Xing, Qian AI, C. QIU, Wentao HUANG a Longjian PIAO. A Big Data Architecture Design for Smart Grids Based on Random Matrix Theory. *IEEE Transactions on Smart Grid*. 2015, **8**. DOI: 10.1109/TSG.2015.2445828.
- [89] TAO, YU, Bin ZHOU a W.-G ZHEN. Application and development of reinforcement learning theory in power systems. *Dianli Xitong Baohu yu Kongzhi/Power System Protection and Control*. 2009, **37**, 122-128.
- [90] MOCANU, E. *Machine learning applied to smart grids*. Eindhoven: Technische Universiteit Eindhoven, 2017, 143 s. ISBN 978-90-386-4338-0. Dostupné z: <https://research.tue.nl/en/publications/machine-learning-applied-to-smart-grids>. Disertace. Department of Electrical Engineering. Vedoucí práce Slootweg, J.G. Proefschrift.
- [91] ZIA, Muhammad, Elhoussin ELBOUCHIKHI a Mohamed BENBOUZID. Microgrids energy management systems: A critical review on methods, solutions, and prospects. *Applied Energy*. 2018, **222**, 1033-1055. DOI: 10.1016/j.apenergy.2018.04.103.
- [92] HE, Xing, Leo CHU, Robert QIU, Qian AI a Zenan LING. A Novel Data-Driven Situation Awareness Approach for Future Grids—Using Large Random Matrices for Big Data Modeling. *IEEE Access*. 2018, , 1-1. DOI: 10.1109/ACCESS.2018.2805815.
- [93] CHU, Leo, Robert QIU, Xing HE, Zenan LING a Yadong LIU. *Massive Streaming PMU Data Modeling and Analytics in Smart Grid State Evaluation Based on Multiple High-Dimensional Covariance Tests*. 2018, **4**, 55-64. DOI: 10.1109/TBDATA.2017.2715165.
- [94] QIU, Robert, Leo CHU, Xing HE, Zenan LING a Haichun LIU. *Spatio-Temporal Big Data Analysis for Smart Grids Based on Random Matrix Theory: A Comprehensive Study*. 2017.
- [95] HAN, Mengjie, Ross MAY, Xingxing ZHANG, Xinru WANG, Song PAN, Da YAN, Yuan JIN a Liguu XU. A review of reinforcement learning methodologies for controlling occupant comfort in buildings. *Sustainable Cities and Society*. 2019, **51**. DOI: 10.1016/j.scs.2019.101748.
- [96] DING, Ming a Xiaoqi YIN. A Review on Multi-Agent Technology in Micro-Grid Control. *Electronics Science Technology and Application*. 2018, **5**. DOI: 10.18686/esta.v5i1.69.

- [97] ZHANG, Z., D. ZHANG a R. QIU. Deep reinforcement learning for power system applications: An overview. *CSEE Journal of Power and Energy Systems*. 2020, **6**(1), 213-225. DOI: 10.17775/CSEEJPES.2019.00920. ISSN 2096-0042.
- [98] SUTTON, Richard a Andrew BARTO. *Reinforcement learning: an introduction*. Second edition. Cambridge, Massachusetts: The MIT Press, 2018. Adaptive computation and machine learning (The MIT Press). ISBN 978-0262039246.
- [99] FRANCOIS, Vincent, Peter HENDERSON, Riashat ISLAM, Marc BELLEMARE a Joelle PINEAU. *An Introduction to Deep Reinforcement Learning*. 2018. DOI: 10.1561/22000000071. Dostupné z: [https://www.researchgate.net/publication/329362838\\_An\\_Introduction\\_to\\_Deep\\_Reinforcement\\_Learning](https://www.researchgate.net/publication/329362838_An_Introduction_to_Deep_Reinforcement_Learning)
- [100] LI, Chong. Deep Reinforcement Learning. *Reinforcement Learning for Cyber-Physical Systems* [online]. Boca Raton, Florida: Chapman and Hall/CRC, 2019, , 125-154 [cit. 2020-06-21]. DOI: 10.1201/9781351006620-6. ISBN 9781351006620. Dostupné z: <https://www.taylorfrancis.com/books/9781351006613/chapters/10.1201/9781351006620-6>
- [101] BERTSEKAS, Dimitri P. *Reinforcement Learning and Optimal Control* [online]. In: . [cit. 2020-06-21]. Dostupné z: <https://www.semanticscholar.org/paper/Reinforcement-Learning-and-Optimal-Control-by-Bertsekas/ed195eea1a2e40b2f0bf1a47150694f9e610eb5a>
- [102] MOCANU, Elena, Decebal MOCANU, Phuong NGUYEN, Antonio LIOTTA, Michael WEBBER, Madeleine GIBESCU a J. SLOOTWEG. On-line Building Energy Optimization using Deep Reinforcement Learning. *IEEE Transactions on Smart Grid*. 2017, . DOI: 10.1109/TSG.2018.2834219.
- [103] WAN, Zhiqiang, Hepeng LI a Haibo HE. *Residential Energy Management with Deep Reinforcement Learning*. 2018, 1 s. DOI: 10.1109/IJCNN.2018.8489210. Dostupné z: <https://ieeexplore.ieee.org/document/8489210>
- [104] MBUWIR, Brida, Mahtab KAFFASH a Geert DECONINCK. *Battery Scheduling in a Residential Multi-Carrier Energy System Using Reinforcement Learning*. 2018, 1 s. DOI: 10.1109/SmartGridComm.2018.8587412. Dostupné z: <https://ieeexplore.ieee.org/document/8587412>
- [105] WU, Jingda, he HONGWEN, Jiankun PENG, Yuecheng LI a Zhanjiang LI. Continuous reinforcement learning of energy management with deep Q network for a power split hybrid electric bus. *Applied Energy*. 2018, **222**, 799-811. DOI: 10.1016/j.apenergy.2018.03.104.
- [106] WAN, Zhiqiang, Hepeng LI a Danil PROKHOROV. Model-Free Real-Time EV Charging Scheduling Based on Deep Reinforcement Learning. *IEEE Transactions on Smart Grid*. 2018, , 1-1. DOI: 10.1109/TSG.2018.2879572.
- [107] HU, Yue, Weimin LI, Kun XU, Taimoor ZAHID, Feiyan QIN a Chenming LI. Energy Management Strategy for a Hybrid Electric Vehicle Based on Deep

Reinforcement Learning. *Applied Sciences*. 2018, **8**, 187. DOI: 10.3390/app8020187.

- [108] QI, Xuewei, Yadan LUO, Guoyuan WU, Kanok BORIBOONSOMSIN a Matthew BARTH. Deep reinforcement learning enabled self-learning control for energy efficient driving. *Transportation Research Part C: Emerging Technologies*. 2019, **99**, 67-81. DOI: 10.1016/j.trc.2018.12.018.
- [109] WU, Yuankai, Huachun TAN, Jiankun PENG, Hailong ZHANG a he HONGWEN. Deep reinforcement learning of energy management with continuous control strategy and traffic information for a series-parallel plug-in hybrid electric bus. *Applied Energy*. 2019, **247**, 454-466. DOI: 10.1016/j.apenergy.2019.04.021.
- [110] VÁZQUEZ-CANTELI, José a Zoltán NAGY. Reinforcement learning for demand response: A review of algorithms and modeling techniques. *Applied Energy*. 2019, **235**, 1072-89. DOI: 10.1016/j.apenergy.2018.11.002.
- [111] SIANO, Pierluigi. Demand response and smart grids—A survey. *Renewable and Sustainable Energy Reviews*. 2014, **30**, 461-478. DOI: <https://doi.org/10.1016/j.rser.2013.10.022>. ISSN 1364-0321. Dostupné z: <http://www.sciencedirect.com/science/article/pii/S1364032113007211>
- [112] LU, Renzhi a Seung HONG. Incentive-based demand response for smart grid with reinforcement learning and deep neural network. *Applied Energy*. 2019, **236**, 937-949. DOI: 10.1016/j.apenergy.2018.12.061.
- [113] ZHANG, X. Y. *A data-driven approach for coordinating air conditioning units in buildings during demand response events*. Arlington, Virginia, 2019. Dostupné z: [https://vtechworks.lib.vt.edu/bitstream/handle/10919/87517/Zhang\\_X\\_D\\_2019.pdf?sequence=1&isAllowed=y](https://vtechworks.lib.vt.edu/bitstream/handle/10919/87517/Zhang_X_D_2019.pdf?sequence=1&isAllowed=y). Disertace. Virginia Tech. Vedoucí práce S. Rahman.
- [114] HAO, Jun. *Multi-agent Reinforcement Learning Embedded Game for the Optimization of Building Energy Control and Power System Planning* [online]. 2019 [cit. 2020-06-26]. Dostupné z: <https://arxiv.org/abs/1901.07333>
- [115] GHASEMKHANI, Amir a Lei YANG. *Reinforcement Learning Based Pricing for Demand Response* [online]. 2018, 6 s. [cit. 2020-06-26]. DOI: 10.1109/ICCW.2018.8403783. Dostupné z: [https://www.researchgate.net/publication/326218461\\_Reinforcement\\_Learning\\_Based\\_Pricing\\_for\\_Demand\\_Response](https://www.researchgate.net/publication/326218461_Reinforcement_Learning_Based_Pricing_for_Demand_Response)
- [116] T, Remani, Jasmin E.A a Imthias AHAMED. Residential Load Scheduling With Renewable Generation in the Smart Grid: A Reinforcement Learning Approach. *IEEE Systems Journal*. 2018, , 1-12. DOI: 10.1109/JSYST.2018.2855689.
- [117] [ CHIS, Adriana, Jarmo LUNDÉN a Visa KOIVUNEN. Reinforcement Learning-Based Plug-in Electric Vehicle Charging With Forecasted Price. *IEEE Transactions on Vehicular Technology*. 2016, **66**(5), 1-1. DOI: 10.1109/TVT.2016.2603536.

## 7 SEZNAM ZKRATEK, SYMBOLŮ, OBRÁZKŮ A TABULEK

### 7.1 Seznam zkratek

CAD	Computer-Aided Drafting
CPS	Cyber-Physical Systems
IoT	Internet of Things
PLC	Programmable Logic Controller
AI	Artificial Intelligence
SVM	Support Vector Machines
ANN	Artificial Neural Network
DT	Decision Trees
K-NN	K-Nearest Neighbors
PNN	Probabilistic Neural Network
BpNN	Backpropagation Neural Network
RF	Random Forest
GPR	Gaussian Process Regression
NSGA-II	Nondominated Sorting Genetic Algorithm II
SVR	Support Vector Regression
PR	Polynomial Regression
MOTLBO	Multi-Objective Teaching Learning Based Optimization
MLR	Multiple Linear Regression
DNA	Deoxyribonucleic Acid
LAoD	Logical Analysis of Data
EA	Evolutionary Algorithm
GA	Genetic Algorithm
TLBO	Teaching Learning Based Optimization
ABC	Artificial Bee Colony
SL	Supervised Learning
UL	Unsupervised Learning
TDIDT	Top-Down Induction of Decision Trees
MLP	Multi-Layer Perceptron
PCA	Principal Component Analysis
ICMIR	International Conference on Mechatronics and Intelligent Robotics
SMPM	International Conference on Sustainable Materials Processing and Manufacturing

ML	Machine Learning
WKNN	Weighted K-Nearest Neighbor
PCA	Principal Component Analysis
DPCA	Dynamic Principal Component Analysis
DRL	Deep Reinforcement Learning
MCES	Multi-Carrier Energy System
DQL	Deep Q-Learning
DDPG	Deep Deterministic Policy Gradient
RL	Reinforcement Learning
DNN	Deep Neural Network
GRA	Grey Relational Analysis

## 7.2 Seznam obrázků

Obr.1) Technologie průmyslu 4.0.....	17
Obr.2) Přehled průmyslových revolucí v čase.....	18
Obr.3) Postup použití strojového učení při řešení problému.....	20
Obr.4) Příklad rozhodovacího stromu .....	25
Obr.5) Příklad vrstev neuronové sítě .....	26
Obr.6) Příklad použití K-means Clustering algoritmu ve dvou rozměrné oblasti.....	27
Obr.7) Příklad PCA algoritmu v dvou rozměrné oblasti .....	28
Obr.8) Základní rámec metody Deep Reinforcement Learning .....	33
Obr.9) Hlavní algoritmy metody DRL a jejich vzájemné vztahy.....	34

## 7.3 Seznam tabulek

Tab 1) Výsledky aplikací metod strojového učení na metody obrábění .....	38
--------------------------------------------------------------------------	----