

VYUŽITÍ METOD AI PRO KLASIFIKACI OBRAZU ŽELEZNIČNÍCH TRAŤOVÝCH NÁVĚSTIDEL

USE OF AI METHODS FOR CLASSIFICATION OF RAILWAY SIGNALS IMAGES

Pavla ŠMÍDOVÁ¹, Stanislav MACHALÍK²

Abstrakt

Článek se zabývá využitím metod umělé inteligence (AI), konkrétně detekce a klasifikace obrazu v železniční dopravě. Úvodní kapitoly popisují možnosti, které AI v současnosti v různých oborech vědy a průmyslu nabízí, dále následuje popis využití AI v prostředí Custom Vision pro klasifikaci obrazu železničních traťových návěstidel. V závěru je zhodnocení provedené simulace užití AI a úvaha o možném využití v reálném provozu.

Klíčová slova

umělá inteligence, železniční doprava, Custom Vision, klasifikace obrazu, traťová návěstidla

Abstract

The article looks into the use of artificial intelligence (AI) methods, specifically image detection and classification in railway transport. The introductory chapters describe the possibilities that AI currently offers in various fields of science and industry, followed by a description of the use of AI in the Custom Vision environment for image classification of railway track signals. In the end, there is an evaluation of the simulation of the use of AI and a consideration of the possible use in real operation.

Keywords

artificial intelligence, railway transport, Custom vision, image classification, railway track signals

1 ÚVOD

Umělá inteligence – AI (Artificial Intelligence) – je v současnosti velmi skloňovaný pojem. Co ale přesně znamená? Tímto pojmem se dnes označují obory a aplikace, které se dříve nazývaly i jinak – je možné do ní zahrnout téměř cokoli od statistiky a obchodní analytiky až po manuálně kódované příkazy. Tato oblast se neustále redefinuje, některá témata jsou klasifikována jako nespádající pod AI a objevují se témata nová [1].

Některé technologie AI existují už více než 50 let, ale pokrok ve výpočetní technice, přístup k obrovskému množství dat, nové algoritmy, možnosti přenosu dat apod. v posledních letech vedly k významnému průlomu v této oblasti.

¹ Ing. Pavla Šmídová, ČD – Informační systémy, a.s. Hlaváčova 205, 530 02 Pardubice. Tel.: +420 776 292 200, e-mail: smidova.pavla@gmail.com

² Ing. Stanislav Machalík, Ph.D., University of Pardubice, Faculty of Transport Engineering. Katedra informatiky a matematiky v dopravě, Studentská 95, 532 10 Pardubice. Tel.: +420 466 036 181, e-mail: stanislav.machalik@upce.cz

Jako ve všech oborech lidské činnosti, i v dopravě lze uplatnit metody AI s velkými výhodami – zvýšení bezpečnosti a rychlosti, celkové efektivity dopravy. Žhavým tématem je výzkum autonomní jízdy vozidel.

V tomto článku je popsán výzkum, provedený za účelem zjištění možnosti využití metod AI pro klasifikaci obrazu železničních traťových návěstidel. Výzkum probíhal v prostředí služby Azure Custom Vision [1], které je blíže popsáno v kapitole 4.

2 DEFINICE AI

Oficiální a přesná definice AI neexistuje. Projevuje se zde rozpor mezi pojetím statistickým a pojetím blízkým matematické logice. Bývá uváděna jako schopnost systémů či strojů napodobovat lidskou inteligenci pro řešení úkolů, iterativně se vylepšující na základě shromážděných informací. Jako AI je také označován obor informatiky zabývající se tvorbou strojů řešících komplexní úlohy [2].

Klíčovými vlastnostmi AI jsou autonomie (schopnost provádět úkoly v komplexních prostředích bez neustálého řízení uživatelem) a adaptabilita (schopnost zlepšit výkon prostřednictvím učení se ze zkušeností).

AI je součástí několika úzce souvisejících témat:

Strojové učení (Machine Learning) je proces použití matematických modelů dat, pomocí kterých se počítač učí bez přímých instrukcí a zlepšují svůj výkon v dané úloze na základě narůstajících zkušeností nebo objemu dat [3].

V současnosti se používají dva hlavní druhy algoritmů strojového učení:

- s učitelem – algoritmus dostává informace, jaké závěry má učinit, je trénován datovou sadou, která je již označena a má předdefinovaný výstup, užívá se nejčastěji.
- bez učitele – využívá nezávislejší přístup, ve kterém se systém učí rozpoznat složité procesy a vzorce bez trvalého vedení člověka [4].

Datová věda (Data Science) zahrnuje několik dílčích disciplín – strojové učení, statistika, některé aspekty počítačových věd včetně algoritmů, uchovávání dat a vývoje webových aplikací [3].

Hluboké učení (Deep Learning) se inspirovalo zpracováváním vizuálních informací v mozku, kdy tyto informace přichází očima a jsou zachyceny sítnicí, což umožňuje síti poznat složitější struktury, aniž by vyžadovala nereálně velké objemy dat. Technicky je realizováno jako metody strojového učení, kdy se několik vrstev jednoduchých zpracovávajících jednotek spojí do sítě tak, že vstup do systému postupně všemi těmito vrstvami prochází [1].

Využití AI v praxi může být velmi široké, např. počítačové vidění a rozpoznávání řeči pro průzkum okolního prostředí, zpracovávání přirozeného jazyka, vyhledávání uložených informací a usuzování v nejistotě za účelem zpracovávání instrukcí a předvídání následků potenciálních akcí, kognitivní modelování a emoční AI.

Tento příspěvek je zaměřen na ukázkou problematiky využití detekce a klasifikace obrazu železničních traťových návěstidel v prostředí Custom Vision [2].

3 POPIS SOUČASNÉ SITUACE

S rychlým rozvojem technologií, rychlosti a kapacity přenosu dat se nabízí možnosti využití výše zmíněných metod AI v různých oborech. Výhodou popsané technologie Custom Vision je již připravené rozhraní bez nutnosti vlastní implementace vlastních algoritmů. Níže je popsáno několik zajímavých projektů s použitím algoritmů a metod AI v oblasti detekce objektů v obrazové předloze a jejich klasifikace.

V práci [6] je popsáno použití konvoluční neuronové sítě pro detekci dopravních značek za účelem získání dobrých výsledků detekce v kombinaci s co možná nejkratší dobou zpracování.

Výsledkem práce bylo zjištění vysoké úspěšnosti detekce při trénování modelu na syntetických datech a odpovídající nutnost anotace tisíců reálných snímků.

V případech, kdy je nutné zvažovat kapacity výpočetního výkonu (např. na mobilních zařízeních) lze s výhodou použít kombinovanou učící metoda pro klasifikaci a regresi Random Forest. Její výsledky jsou porovnatelné s použitím neuronových sítí za použití výrazně nižšího výpočetního výkonu. Metoda je popsána např. ve zdroji [7].

V praxi využívá v ČR metody AI v dopravě např. firma Camea, především pro detekci, rozpoznání, a vyhodnocení dopravní situace kompaktními kamerami. Detekuje a dokumentuje vozidla jedoucí na světelných křižovatkách nebo přechodech pro chodce na červenou. Kamery zachytí vozidla projíždějící na červenou na příčné čáře [8].

V železniční dopravě se AI využívá např. u německých Deutsche Bahn [9], konkrétně na linkách S-Bahn ve Stuttgartu. Zde dokáže použitý systém vypočítat několik variant řízení vlaků v reálném čase. Dispečeri mohou varianty rychle měnit, což výrazně ovlivňuje přesnost dopravy. Je tak možné minimalizovat možná zpoždění, zejména v případě různých poruch či narušení dopravy.

DB také využívají AI k automatickému vyhodnocení obrazů kamer nebo dat senzorů, což pomáhá vytvořit konkrétní požadavek na údržbu vlaku. Dochází tak k významnému zkrácení doby, za kterou se například kontroluje střecha vlaků ICE, a to z několika hodin až na jednotky minut. Další projekty se soustředí na předpovídání poruch.

Na několika specializovaných pracovištích – DT – Výhybkárna a strojírna, a.s., RETIA, a.s., Univerzita Pardubice – Dopravní fakulta Jana Pernera, Vysoké učení technické v Brně - Fakulta stavební probíhá vývoj inteligentního autonomního diagnostického systému pro výhybky pro vysokorychlostní i konvenční železniční tratě Výhybka 4.0 [10]. Data, získaná ze senzorů, bude systém metodami AI vyhodnocovat a v cílovém stavu bude schopen autonomně a bez zásahu obsluhy vyhodnocovat stav výhybky a generovat doporučení údržby pro správce infrastruktury [11].

4 POUŽITÍ CUSTOM VISION

Azure Custom Vision je služba pro rozpoznávání obrazů, která umožňuje sestavovat, nasazovat a zdokonalovat vlastní modely – identifikátory. Identifikátor obrazu používá popisky (labels), které jsou přiřazeny k objektům určeným pro rozpoznání. Služba Custom Vision používá algoritmus strojového učení s učitelem.

Azure Custom Vision je služba pro rozpoznávání obrazů, která umožňuje sestavovat, nasazovat a zdokonalovat vlastní identifikátory. Identifikátor používá popisky (které reprezentují třídy nebo objekty) obrazů podle jejich vizuálních vlastností. Pro analýzu používá algoritmus strojového učení s učitelem. Uživatel označí na obrazech objekty prostřednictvím popisků a algoritmus na těchto obrazech trénuje. Vypočte svou vlastní přesnost tím, že se na stejných obrázcích otestuje sám. Po natrénování algoritmu je možné ho využít pro testování, nové trénování, a nakonec ho použít v aplikaci pro rozpoznávání obrazů. Model lze také exportovat pro offline použití.

Možnosti služby Custom Vision lze rozdělit do dvou oblastí:

Klasifikace obrazu používá jeden nebo více popisků na obraz, podle kterých klasifikuje objekty.

Detekce objektu je podobná, ale vrací navíc souřadnice v obrazu, kde lze nalézt použité popisky.

Služba Custom Vision je optimalizována tak, aby rychle rozpoznala hlavní rozdíly mezi obrázky, takže je možné vytvářet modely již s poměrně malými vstupními daty, ale není optimální pro detekci drobných rozdílů v obrázcích.

Při vytváření modelu lze také vybrat z několika variant algoritmu, které jsou optimalizované pro určitý druh obrazů – např. orientačních bodů.

Služba Custom Vision je k dispozici jako sada nativních SDK (Software Development Kit) prostřednictvím webového rozhraní, obě varianty lze také kombinovat [2].

V této kapitole jsou popsány vybrané aplikace služby Custom Vision využívající detekce objektů v obraze a jejich klasifikaci.

Bylo provedeno rozpoznávání několika objektů na trati a vybraných návěstidel (viz jednotlivé podkapitoly). Nejprve byly sledovány jednoduché (co do obrazové složitosti) objekty, další aplikace vycházely z rozpoznání komplikovaných objektů, u kterých se vyskytují různé varianty – např. číslice.

Pro trénování modelu byly použity obrazy, na kterých se vyskytovala natrénovaná návěstidla většinou jednou, při testování ale byly rovněž použity obrazy, na kterých se vyskytovalo i více návěstidel. Zdrojem obrazů byly záběry z reálného provozu, z kamery umístěné v kabině strojvedoucího; tímto děkuji za svolení autora videí, vlastníka kanálu videí na Youtube [12] a blogu [13].

Zajímavé je srovnání výsledků proběhlých iterací (= opakujících se procesů trénování modelu na obrazech). Tyto násobné iterace nebyly původně záměrem – trénování modelu bylo spouštěno opakovaně z důvodu přidávání dalších objektů, u nejdříve přidaných objektů bylo tedy provedeno nejvíce iterací. Po srovnání výsledků iterací byla ale zjištěna užitečnost opakování iterací, které původně nedávaly nejlepší výsledky, více v kapitole 4.4.


Detailní popis návěstidel je uveden ve zdroji [14].

4.1 Objekt telefonního sloupku

Objekt telefonního sloupku je jednoduchý objekt, často se vyskytující u trati. Jeho výhodou je neměnný vzhled – vždy je na obraze k rozpoznání jako bílý čtverec (přibližně) s písmenem T uvnitř.

Pro trénování identifikátoru bylo v první iteraci použito 17 obrazů a po provedení pokusu již nevystala potřeba počet obrazů pro trénování zvyšovat, protože výsledky rozpoznávání byly dobré, obzvlášť po opakování iterací.

Např. na tomto obraze byl objekt identifikován s vysokou pravděpodobností, a to i přes relativně neostrý a natočený objekt:



Obr. 1 Objekt telefonní sloupek

Z patnácti testovaných obrazů byla identifikace provedená správně u 14 obrazů s pravděpodobností vždy vyšší než 97 %.

4.2 Návěstidlo hektometrovník

Pro návěstidlo hektometrovník bylo k dispozici 40 vzorových obrazů. Přes předpoklad problému s proměnlivým obsahem objektu (číslíce) byly výsledky rozpoznávání dobré. Ze dvaceti testovacích obrazů byly všechny správně rozpoznány s pravděpodobností vyšší než 97 %.




Obr. 2 Objekt Hektometrovník

4.3 Návěstidlo Vozidlo se blíží k zastávce

Pro tento popis bylo použito 15 obrazů pro trénování, následně byla predikce provedena na deseti obrazech.

Zde byl problém s počtem pruhů na návěstidle – ve třech případech byl na obraze kromě správně identifikovaného celého návěstidla s pravděpodobností vyšší než 93 % ještě identifikována část návěstidla s jedním nebo dvěma pruhy také jako toto návěstidlo, s pravděpodobností cca 20 %. Řešením je nastavení filtru výsledků až od určité úrovně pravděpodobnosti nebo doplnění modelu negativním trénováním, které slouží pro odfiltrování nežádoucích objektů.



Obr. 3 Objekt Vozidlo se blíží k zastávce



Obr. 4 Objekt Vozidlo se blíží k zastávce

4.4 Srovnání výsledků proběhlých iterací

Vysvětlení použitých pojmů:

- **Precision** — označuje procento identifikovaných klasifikací, které byly správné.
- **Recall** — indikuje procento skutečných klasifikací, které byly správně identifikovány.
- **mAP** – Mean Average Precision — Střední přesnost je průměrná hodnota průměrné přesnosti (AP), kde je AP je oblast pod křivkou veličiny Precision/Recall.

Do první iterace byl zahrnut pouze objekt telefonní sloupek. Výsledky iterace byly tyto:

Tab. 1 První iterace

Tag	Precision	Recall	A.P.	Počet obrazů
telefon	80,0 %	100,0 %	67,9 %	17

Do druhé iterace byl navíc zahrnut popisec „hektometrovník“ a „rychlostník“, s těmito výsledky:

Tab. 2 Druhá iterace

Tag	Precision	Recall	A.P.	Počet obrazů
telefon	50,0 %	100,0 %	100,0 %	17
hektometrovník	61,5 %	100,0 %	97,5 %	40
rychlostník	66,7 %	100,0 %	100,0 %	30

U objektu „telefon“ vidíme pokles přesnosti s přidáním dalších rozpoznávaných objektů. To bylo způsobeno pravděpodobně nevyrovnaným počtem obrazů pro trénování, na což upozornil i samotný model. V další aplikaci je tedy potřebné trénovat všechny objekty na přibližně stejném počtu obrazů.

Ve třetí iteraci byl přidán popisec „zastavka“ (návěstidlo Vozidlo se blíží k zastávce):

Tab. 3 Třetí iterace

Tag	Precision	Recall	A.P.	Počet obrazů
telefon	50,0 %	100,0 %	100,0 %	17
rychlostník	66,7 %	100,0 %	100,0 %	30
zastavka	75,0 %	100,0 %	100,0 %	15
hektometrovník	80,0 %	100,0 %	100,0 %	40

V této iteraci u objektu hektometrovník naopak došlo ke zvýšení přesnosti.

4.5 Predikce s nenatřénovanými obrazy

Bylo provedeno několik desítek predikcí s obrazy, ve kterých se nevyskytovala buď žádná návěstidla, nebo návěstidla jiného typu, než byla natřénována. Ve většině případů, kdy na obraze nebyl objekt, vizuálně podobný některému natřénovanému návěstidlu, byl výsledek správný, tzn. nebylo označeno nic.

V případech, kdy se na obraze vyskytovalo návěstidlo, které nebylo natřénováno, bylo často chybně identifikováno jako některý z natřénovaných objektů.

Z této skutečnosti vyplývá potřeba zahrnout do identifikátoru co nejvíce návěstidel, aby nedocházelo k záměnám natřénovaných a nenatřénovaných objektů.

5 ZÁVĚR

Provedené pokusy na rozpoznávání objektů v obrazech pomohly nastínit možnosti použití této metody v reálném provozu.

Pro návěstidla, která se skládají z několika opakujících se částí (např. pruhy), je vhodné provést trénování modelu na velkém počtu obrazů. Dále z pokusu vyplynula potřeba zahrnout do modelu co nejvíce typů návěstidel a dalších objektů na trati – i těch, které nebude potřeba rozpoznávat. Důvodem je zaměňování návěstidel s nenatréňovanými objekty. Samozřejmě, čím více obrazů pro trénování bude použito, tím přesnější bude model. Rovněž kvalita a umístění kamery (či použití více kamer) ovlivňuje výsledky rozpoznávání.

Tato oblast skýtá velký prostor pro výzkum a vývoj, jak bylo naznačeno ve článku. Při výzkumu je potřeba možné použití konzultovat s dopravci, kteří ze svého hlediska (finance, užitečnost) zhodnotí optimální příležitosti využití AI pro snímání obrazu trati z kabiny strojvedoucího.

Výzkum byl podporován Univerzitou Pardubice v rámci projektu Rozvoj kvality vzdělávání, hodnocení a strategického řízení na Univerzitě Pardubice, reg. č. CZ.02.2.69/0.0/0.0/16_015/0002320.



EVROPSKÁ UNIE
Evropské strukturální a investiční fondy
Operační program Výzkum, vývoj a vzdělávání



Literatura

- [1] Jak definovat umělou inteligenci? In: *Elements of AI* [online]. 2020 [cit. 11. 04. 2021]. Dostupné z: <https://course.elementsofai.com/cs/1/1>
- [2] FARLEY, P. Co je Custom Vision? In: *Microsoft* [online]. 2021 [cit. 03. 06. 2021]. Dostupné z: <https://docs.microsoft.com/cs-cz/azure/cognitive-services/custom-vision-service/overview>
- [3] Co je umělá inteligence (AI)? In: *Oracle* [online]. 2021 [cit. 03. 06. 2021]. Dostupné z: <https://www.oracle.com/cz/artificial-intelligence/what-is-ai/>
- [4] Co je machine learning? In: *Microsoft* [online]. 2021 [cit. 04. 06. 2021]. Dostupné z: <https://azure.microsoft.com/cs-cz/overview/what-is-machine-learning-platform/>
- [5] Co je strojové učení? In: *Oracle* [online]. 2021 [cit. 03. 06. 2021]. Dostupné z: <https://www.oracle.com/cz/data-science/machine-learning/what-is-machine-learning/>
- [6] KOČICA, F. *Detekce dopravních značek v obraze a videu*. Brno, 2019. Bakalářská práce. Vysoké učení technické v Brně, Fakulta informačních technologií. Dostupné z: <https://www.fit.vut.cz/study/thesis/22070/>
- [7] YIU, T. Understanding Random Forest. In: *Towards Data Science* [online]. 2019 [cit. 11. 06. 2021]. Dostupné z: <https://towardsdatascience.com/understanding-random-forest-58381e0602d2>
- [8] Kamerový detekční systém. In: *Camea* [online]. 2020 [cit. 03. 05. 2021]. Dostupné z: <https://www.camea.cz/cz/doprava/kamerovy-detecni-system/>
- [9] ROVNÝ, T. Umělá inteligence na železnici? Efektivnější řízení provozu i předpovídání nehod. In: *Ekonomický deník* [online]. 2021 [cit. 06. 05. 2021]. Dostupné z: <https://ekonomickydenik.cz/umela-inteligence-na-zeleznici-efektivnejsi-rizeni-provozu-i-predpovidani-nehod/>
- [10] Výhybka 4.0. In: *TACR Starfos* [online]. 2020 [cit. 11. 06. 2021]. Dostupné z: <https://starfos.tacr.cz/cs/project/CK01000091>

- [11] Výhybka 4.0. In: *Univerzita Pardubice, Dopravní fakulta Jana Pernera* [online]. 2020 [cit. 13. 06. 2021]. Dostupné z: <https://dfjp.upce.cz/projekt/1035362>
- [12] Strojvedouci COM. Onboard jízdy vlakem, playlist. In: *YouTube*. 2021 [cit. 10. 04. 2021]. Dostupné z: <https://www.youtube.com/playlist?list=PLmgNqYybGmTcB8lqU4AnWGT-R5mKhO-S>
- [13] *Strojvedoucí: Život a příhody strojvedoucího Českých drah* [online]. © 2021 strojvedouci.com [cit. 02. 04. 2021]. Dostupné z: <https://www.strojvedouci.com/>
- [14] *Dopravní a návěštní předpis SŽDC D1* [online]. Praha: SŽDC, 2018 [cit. 02. 04. 2021]. Dostupné z: <https://provoz.spravazeleznice.cz/portal/Show.aspx?oid=1565121>