



## Automatické ovládání žaluzí s využitím strojového učení

Vojtěch Breník<sup>1</sup>

### 1 Úvod

Stínění oken v pozemních stavbách určených k bydlení se využívá k regulaci teploty a zajištění soukromí obyvatel. Jednou z možností stínění jsou venkovní žaluzie osazené pohonem na dálkové ovládání, díky kterému je možné žaluzie řídit automaticky, viz Lubinová (2013). Tato práce se zabývá návrhem systému pro automatické řízení takových žaluzí včetně návrhu a realizace měřicích zařízení použitelných pro měření veličin užitečných při rozhodování systému a možnostmi využití strojového učení k ovládání žaluzí v reálném čase. Zkoumá také časový vývoj použitých algoritmů při opakovém učení na postupně sbíraných datech s ohledem na měnící se požadavky uživatele a měnící se podmínky v průběhu roku. Veškerá měření probíhala v domě autora, na kterém jsou instalovány použité venkovní žaluzie.

### 2 Definice úlohy a sběr dat

Podle faktorů, které mohou mít vliv na rozhodování člověka o nastavení žaluzie, bylo určeno 15 vstupních veličin (příznaků) – den v roce, den v týdnu, denní čas, přítomnost uživatele v domácnosti, teplota v místnosti a venku, intenzita osvětlení uvnitř a venku, hodinová předpověď teploty na 3 h dopředu a předpověď nejvyšší denní teploty, odhad stavu počasí, rychlosti a směru větru. Teplota a intenzita osvětlení uvnitř i venku byla měřena zařízeními vlastní konstrukce, přítomnost uživatele se vyhodnocovala na základě zeměpisné polohy jeho telefonu a ostatní nečasové veličiny se získávaly pomocí rozhraní pro programování aplikací (API) OpenWeather.

Stav žaluzí (výstup navrhovaného systému) vyjádřený pomocí míry vytažení a úhlu naklopení lamel se získával z API výrobce pohonu žaluzie. Stav se společně s hodnotami příznaků periodicky ukládal do databáze. V případě ruční změny stavu uživatelem se uložil vzorek dat i mimo periodu.

Úlohou je na základě hodnot příznaků odhadnout vhodný stav žaluzie (regrese). K tomu byly využity 3 různé metody (sekce 4), 2 z nich využívaly neuronové sítě (NS).

### 3 Zařízení pro měření teploty a osvětlení

Navržená zařízení pro měření teploty vzduchu a intenzity osvětlení využívají modulu s ESP8266, který integruje jednočipový počítač (MCU) a kompletní řešení WiFi. K MCU je připojen pomocí standardního rozhraní 1-Wire digitální teploměr DS18B20 a pomocí I<sup>2</sup>C senzor intenzity osvětlení TSL2591. Zapojení je realizováno na desce plošných spojů vlastní výroby. Naměřené hodnoty jsou přenášeny po WiFi pomocí protokolu MQTT.

Jedno z měřicích zařízení je umístěno uvnitř místnosti, kterou zatemňuje vybraná žaluzie, druhé pak na střeše domu. Před povětrnostními vlivy je venkovní zařízení chráněno plastovou

<sup>1</sup> student bakalářského studijního programu Kybernetika a řídicí technika, specializace Umělá inteligence a automatizace, e-mail: vbrenik@students.zcu.cz

krabičkou vytištěnou na 3D tiskárně s průhledným okénkem pro senzor intenzity osvětlení.

## 4 Automatické ovládání žaluzií

Pro automatické ovládání žaluzií byly navrženy tři regresory – první z nich je založen na ručně vytvořených pravidlech („Ifelse“), další dva využívaly k odhadu výstupu NS (jeden dopřednou NS – „FFNN“, druhý rekurentní – konkrétně LSTM). Struktura NS a některé parametry jejich trénování (batch size, počet epoch) byly zvoleny na základě úspěšnosti kombinací vybraných hodnot těchto parametrů. Trénovány byly na náhodně vybrané podmnožině dat uložených v databázi. FFNN využívala pro odhad hodnoty příznaků v jednom časovém okamžiku, LSTM pak jejich posloupnost ze 64 po sobě následujících časových okamžiků. Porovnání jednotlivých regresorů a jimi poskytovaných výsledků shrnuje tabulka 1.

	Ifelse	FFNN	LSTM
Počet parametrů	17	817	53634
Doba predikce [ms]	250	30	430
Doba trénování [s]	-	1839	12129
MSE	0,120	0,0246	0,00426

**Tabulka 1:** Porovnání vybraných vlastností regresorů. Doba predikce platí pro 400 vzorků.

Obě NS se opakovaně přetrénovávaly na nově sesbíraných datech, díky čemuž se mohly přizpůsobovat novým skutečnostem v datech a postupně zvyšovat přesnost svého odhadu. Další výhodou využití strojového učení je i skutečnost, že vhodné nastavení vyvstane z dat samo a uživatel se tak nemusí starat o ruční nastavení časových i jiných závislostí, které je jinak nutné v tradičních systémech (např. regresor Ifelse), což ukázal i Popa et al. (2018).

Byla vyhodnocena důležitost příznaků metodou *Permutation feature importance*, viz Breiman (2001), pro jednotlivé NS. Pro oba modely jsou důležité zejména časové údaje a intenzita osvětlení uvnitř i venku.

Pro systém bylo vytvořeno grafické uživatelské rozhraní jako webová aplikace, které umožňuje ruční ovládání žaluzie, zobrazení nasbíraných dat, simulaci funkce některých regresorů pro libovolné zadané hodnoty příznaků a vizualizaci historických hodnot příznaků, skutečného řízení a řízení navrhovaného regresory na základě skutečných dat v grafech.

Ukázalo se, že neuronové sítě při ovládání žaluzie dosahují přesnějších výsledků než obdobný systém zkonstruovaný ručně pomocí pravidel. Opakování trénování na nově sbíraných datech postupně vylepšuje přesnost odhadu.

## Literatura

Breiman, L. (2001) Random Forests. *Machine Learning* 45, s. 5–32.

DOI: 10.1023/A:1010950718922.

Lubinová Š. (2013) *Stínění oken: žaluzie, rolety, markýzy a slunolamy*. Grada Publishing,  
ISBN: 978-80-247-4579-4.

Popa et al. (2018) Deep learning model for home automation and energy reduction in a smart home environment platform. *Neural Computing and Applications* 31.5, s. 1317–1337.  
DOI: 10.1007/s00521-018-3724-6.