

## Automatická detekce chyb na mateřských deskách

Michal Medek<sup>1</sup>

### 1 Úvod

Neuronové sítě jsou v posledních letech více a více používány pro automatizování výroby. Jejich hlavní předností je schopnost učit se. Síť je schopná se v čase zdokonalovat a dosahovat tak vyšší úspěšnosti na základě předchozích špatných rozhodnutí. Nejlepších výsledků v podobných úlohách dosahují konvoluční neuronové sítě.


Cílem práce bylo vytvořit program, který za pomoci strojového učení bude s co možná největší úspěšností rozhodovat, zda jsou základní desky televizorů společnosti Panasonic v pořádku nebo ne. V práci bylo využito několik konvolučních neuronových sítí a implementován systém, který umožňuje detekovat a označit chyby na základní desce.

Výsledný program by měl být v případě spokojenosti zákazníka nasazen a působit tak jako takzvaný druhý čtenář pro dodatečnou kontrolu desek. Může se totiž stát, že se pracovník kvality přehlédne a nebo si chyby nevšimne. Další možné využití programu je ještě před první kontrolou zúžit množinu potenciálně vadných desek a upozornit tak pouze na tyto desky. Dostatečně zdokonalený program by v budoucnu pracovníka kvality mohl nahradit úplně.

### 2 Podoba řešení

Pro realizaci projektu byla použita označovaná data v podobě 768 obrázků ve formátu SVG a ke každému z nich obrázek o velikosti 1280 x 1024 pixelů ve formátu JPG. Na snímcích, které byly označeny jako chybné, můžeme najít 13 různých chyb a těchto snímků je 33. Od začátku nás tedy trápil velmi malý počet pozitivních snímků.

Obrázek 1: Ukázka z množiny dat




Předzpracování bylo realizováno pomocí údajů o označovaných datech z SVG sou-

<sup>1</sup> student navazujícího studijního programu Inženýrská informatika, obor Softwarové inženýrství, specializace Zpracování přirozeného jazyka, e-mail: mmedek@students.zcu.cz

borů pozitivních snímků, kde jsme nejdříve našli souřadnice stejných chyb a poté na základě těchto souřadnic vyřezali ROI (Region Of Interest) jak z pozitivních, tak z negativních snímků, abychom získali množinu dat pro trénování a testování neuronové sítě. Nad množinou pozitivních snímků byly poté použity geometrické transformace za účelem zvětšení této množiny.

Použitá konvoluční neuronová síť pro detekci chyb je tvořena konvoluční vrstvou následovanou ReLU aktivační funkcí, poté se opakuje stejná kombinace konvoluční vrstvy a ReLU aktivace. Další vrstva je max pooling následovaný dropout vrstvou, která zapříčiní vynulování všech neuronů s aktivační funkcí, jejímž výsledkem je hodnota 0,5. Takto je sestavená část pro extrakci příznaku. Klasifikaci provádí plně propojená neuronová síť s ReLU aktivační funkcí. Poslední vrstvu tvoří dva neurony reprezentující klasifikované třídy a jako aktivační funkce je použit softmax, který se pro výstupní vrstvu obvykle používá.

**Obrázek 2:** Konvoluční neuronová síť Leonard (2015)



### 3 Výsledky a zhodnocení

Výsledkem projektu je funkční prototyp aplikace, která velmi spolehlivě rozpoznává chyby na základních deskách. Největším úspěchem je schopnost sítě spolehlivě rozpoznat na testovaných datech (tedy datech, které síť předtím neviděla) všechny chyby. Zvolená konvoluční síť je velmi malá na rozdíl od jiných publikovaných řešení a s největší pravděpodobností především díky vhodnému předzpracování pracuje velice spolehlivě.

Nutno však říci, že za bezchybnou můžeme síť prohlásit jen v případě prvních deseti druhů chyb, kde při testování nedocházelo k překrytí testovací množiny (byť s transformovanými daty). Ve zbývajících třech případech byla totiž chyba zachycena v obdržených datech pouze jednou.

### Literatura

Leonard, N. (2015) *Torch 7: Applied Deep Learning for Vision and Natural Language*