



Fakulta elektrotechnická  
Katedra elektromechaniky a výkonové elektroniky

# BAKALÁŘSKÁ PRÁCE

Využití neuronových sítí pro predikci zatížení distribučního transformátoru

Autor práce: Jiří Krych  
Vedoucí práce Ing. Václav Mužík

Plzeň 2019

ZÁPADOČESKÁ UNIVERZITA V PLZNI  
Fakulta elektrotechnická  
Akademický rok: 2018/2019

**ZADÁNÍ BAKALÁŘSKÉ PRÁCE**  
(PROJEKTU, UMĚLECKÉHO DÍLA, UMĚLECKÉHO VÝKONU)

Jméno a příjmení: **Jiří KRYCH**  
Osobní číslo: **E16B0025P**  
Studijní program: **B2612 Elektrotechnika a informatika**  
Studijní obor: **Elektrotechnika a energetika**  
Název tématu: **Využití neuronových sítí pro predikci zatížení distribučního transformátoru**  
Zadávací katedra: **Katedra elektromechaniky a výkonové elektroniky**

Z á s a d y p r o v y p r a c o v á n í :

1. Zpracujte úvod do teorie umělých neuronových sítí.
2. Popište hospodárné zatěžování transformátoru v distribuční síti.
3. Provedte základní aplikaci neuronové sítě na reálná data z provozu distribučního transformátoru.
4. Porovnejte výsledky modelu a skutečnosti.

Rozsah grafických prací: podle doporučení vedoucího

Rozsah kvalifikační práce: 30 - 40 stran

Forma zpracování bakalářské práce: tištěná/elektronická

Seznam odborné literatury:

1. KŘIVAN, Miloš. Úvod do umělých neuronových sítí. Vyd. 3., přeprac. Praha: Oeconomica, 2014, 44s. ISBN 978-80-245-2024-7.
2. SIVANANDAM, S. N.; DEEPA, S. N. Introduction to neural networks using Matlab 6.0. Tata McGraw-Hill Education, 2006.
3. LI, Kai; ZHANG, Tao. Forecasting Electricity Consumption Using an Improved Grey Prediction Model. Information, 2018, 9.8: 204.

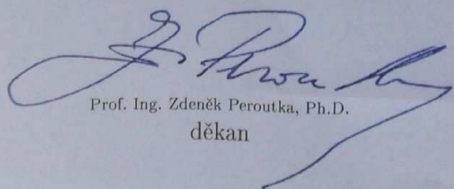
Vedoucí bakalářské práce:

**Ing. Václav Mužík**

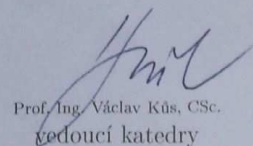
Regionální inovační centrum elektrotechniky

Datum zadání bakalářské práce: **5. října 2018**

Termín odevzdání bakalářské práce: **13. června 2019**

  
Prof. Ing. Zdeněk Peroutka, Ph.D.  
děkan



  
Prof. Ing. Václav Kús, CSc.  
vedoucí katedry

V Plzni dne 5. října 2018

# Abstrakt

Tato bakalářská práce obsahuje popis základní aplikace neuronové sítě pro predikování zatížení z distribučního transformátoru. Teoretická část této práce se věnuje stručnému popisu základního fungování neuronových sítí a provozování distribučního transformátoru. V praktické části je nastíněno vytvoření neuronové sítě a vhodných vstupních hodnot, na kterých závisí predikované zatížení. K procesu vytvoření neuronové sítě a její následné aplikace je využíváno programu Matlab. Tato práce program Matlab rovněž využívá k uskutečnění simulace predikovaného zatížení a k porovnání predikovaných hodnot se skutečnými hodnotami.

Predikce zatížení z transformátoru je užitečná věc, neboť provozovatelé elektrizační soustavy jsou schopni plánovat provoz elektrizační soustavy nebo předpovídat poruchy vzniklé přetížením a mohou tak činit strategická rozhodnutí.

V práci je dosaženo přibližně 94 % úspěšnost predikce zatížení.

## Klíčová slova

neuronová síť, neuron, distribuční transformátor, predikce elektrického zatížení

# Abstract

Krych, Jiří. *Use of artificial neural networks for power load prediction of a distribution transformer* [Využití neuronových sítí pro predikci zatížení distribučního transformátoru]. Pilsen, 2019. Bachelor thesis (in Czech). University of West Bohemia. Faculty of Electrical Engineering. Department of Electromechanics and Power Electronics. Supervisor: Václav Mužík

---

This bachelor thesis contains description of the basic application of artificial neural networks for power load prediction of a distribution transformer. The theoretical part focuses on brief description of the basic operation of the system for neural networks and the operation of distribution transformers. The practical part is dedicated to creation of the neural network and formation of adequate input values. In order to create neural network and in order to implement its application this thesis is using the Matlab program. This thesis also uses the Matlab program to perform simulation of the predicted power load and to compare the predicted values with the nominal values.

Power load prediction of the transformer is mainly beneficial due to the fact, that it enables the operators to plan operation of the power system and it also enables them to predict defects caused by overload. Therefore, the operators can make accordinate decisions.

This thesis accomplishes approximately 94 % load prediction success.

## Keywords

neural network, neuron, transformer, electric load forecasting

## Prohlášení

Předkládám tímto k posouzení a obhajobě bakalářskou práci, zpracovanou na závěr studia na Fakultě elektrotechnické Západočeské univerzity v Plzni.

Prohlašuji, že jsem svou závěrečnou práci vypracoval samostatně pod vedením vedoucího bakalářské práce a s použitím odborné literatury a dalších informačních zdrojů, které jsou všechny citovány v práci a uvedeny v seznamu literatury na konci práce. Jako autor uvedené bakalářské práce dále prohlašuji, že v souvislosti s vytvořením této závěrečné práce jsem neporušil autorská práva třetích osob, zejména jsem nezasáhl nedovoleným způsobem do cizích autorských práv osobnostních a jsem si plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestněprávních důsledků vyplývajících z ustanovení § 270 trestního zákona č. 40/2009 Sb.

Také prohlašuji, že veškerý software, použitý při řešení této bakalářské práce, je legální.

V Plzni dne 11. června 2016

Jiří Krych

.....

Podpis

## Poděkování

Rád bych vyjádřil poděkování vedoucímu mé bakalářské práce Ing. Václavu Mužíkovi za jeho odborné vedení, poskytnutí cenných rad a připomínek, za ochotu při domlouvání konzultací a v neposlední řadě za konzultace samotné. Dále bych rád poděkoval společnosti Meteoblue AG, zpracovávající předpověď počasí, za poskytnutí archivních dat pro město Plzeň. Poděkování patří rovněž mé rodině a mé přítelkyni za důležité připomínky při kontrole této práce a za oporu při studiu.

# Obsah

|   |           |
|---|-----------|
| Seznam obrázků  | viii      |
| Seznam tabulek  | ix        |
| Seznam symbolů a zkratek  | x         |
| <b>1 Úvod</b>   | <b>1</b>  |
| <b>2 Umělá neuronová síť</b>                                      | <b>2</b>  |
| 2.1 Úvod do teorie neuronové sítě . . . . .                       | 2         |
| 2.2 Biologický podtext . . . . .                                  | 3         |
| 2.3 Obecný model umělého neuronu . . . . .                        | 4         |
| 2.3.1 Přenosové funkce . . . . .                                  | 5         |
| 2.4 Modely umělých neuronových sítí . . . . .                     | 6         |
| 2.4.1 Jednovrstvá dopředná síť . . . . .                          | 7         |
| 2.4.2 Vícevrstvá dopředná síť . . . . .                           | 7         |
| 2.4.3 Rekurentní síť . . . . .                                    | 8         |
| 2.5 Učení neuronové sítě . . . . .                                | 8         |
| 2.6 Využití programu Matlab pro simulaci neuronové sítě . . . . . | 9         |
| 2.6.1 Neural Network Fitting Tool GUI . . . . .                   | 10        |
| <b>3 Hospodárné zatěžování transformátoru v distribuční síti</b>  | <b>16</b> |
| 3.1 Transformátor . . . . .                                       | 16        |
| 3.1.1 Princip činnosti . . . . .                                  | 17        |
| 3.1.2 Ztráty transformátoru . . . . .                             | 18        |
| 3.1.3 Účinnost transformátoru . . . . .                           | 19        |
| 3.1.4 Konstrukční uspořádání . . . . .                            | 20        |
| 3.1.4.1 Magnetický obvod . . . . .                                | 20        |
| 3.1.4.2 Vinutí . . . . .  | 20        |
| 3.1.4.3 Nádoba . . . . .  | 20        |
| 3.2 Elektrizační soustava . . . . .                               | 21        |
| 3.2.1 Přenosová soustava . . . . .                                | 22        |
| 3.2.2 Distribuční soustava . . . . .                              | 23        |



|          |  |           |
|----------|--|-----------|
| 3.3      | Transformátor v distribuční síti . . . . .                             | 24        |
| 3.3.1    | Spojení vinutí . . . . .   | 25        |
| 3.3.2    | Převody . . . . .  | 26        |
| 3.3.3    | Regulace napětí - odbočky . . . . .                                    | 26        |
| 3.3.4    | Zatížitelnost . . . . .  | 27        |
| 3.3.5    | Hospodárné zatěžování . . . . .  | 27        |
| <b>4</b> | <b>Aplikace neuronové sítě na reálná data z provozu transformátoru</b> | <b>29</b> |
| 4.1      | Výhody predikce elektrického zatížení . . . . .                        | 29        |
| 4.2      | Druhy přístupů k predikci . . . . .                                    | 30        |
| 4.2.1    | Časové cykly . . . . .   | 30        |
| 4.2.2    | Časové cykly + teplota . . . . .                                       | 30        |
| 4.3      | Vytvoření vstupních hodnot . . . . .                                   | 30        |
| 4.4      | Cílové hodnoty . . . . .   | 32        |
| 4.5      | Architektura použité sítě . . . . .                                    | 32        |
| 4.6      | Predikce zatížení . . . . .  | 33        |
| 4.6.1    | Denní špičkové zatížení . . . . .                                      | 33        |
| 4.6.2    | Celkové denní zatížení . . . . .                                       | 36        |
| 4.6.3    | Hodinové zatížení . . . . .  | 39        |
| <b>5</b> | <b>Porovnání výsledků modelů a skutečnosti</b>                         | <b>42</b> |
| <b>6</b> | <b>Závěr</b>   | <b>45</b> |
|          | Reference, použitá literatura  | 47        |

# Seznam obrázků

|      |  |    |
|------|--|----|
| 2.1  | Model biologického neuronu  Převzat z [1]  . . . . .                             | 3  |
| 2.2  | Obecný model neuronu  Převzat z [1]  . . . . .                                   | 4  |
| 2.3  | Přenosové funkce.  Převzat z [1]  . . . . .                                      | 5  |
| 2.4  | Jednovrstvá dopředná síť  Převzat z [1]  . . . . .                               | 7  |
| 2.5  | Vícevrstvá dopředná síť  Převzat z [2]  . . . . .                                | 7  |
| 2.6  | Rekurentní síť  Převzat z [2]  . . . . .   | 8  |
| 2.7  | Blokový diagram způsobů učení: (a) s učitelem, (b) bez učitele  Převzat z [1]  . | 9  |
| 2.8  | Neural Network Fitting Tool GUI . . . . .  | 10 |
| 2.9  | Vybrání dat pro neuronovou síť . . . . .   | 11 |
| 2.10 | Rozdělení dat do skupin . . . . .  | 12 |
| 2.11 | Zadaní počtu neuronů ve skryté vrstvě . . . . .                                  | 12 |
| 2.12 | Spuštění trénování sítě . . . . .  | 13 |
| 2.13 | Průběh trénování sítě . . . . .  | 13 |
| 2.14 | Generování skriptů a výsledků . . . . .  | 14 |
|      |  |    |
| 3.1  | Schématické znázornění 1-fázového transformátoru  Převzat z [7]  . . . . .       | 18 |
| 3.2  | Zjednodušené schéma elektrizační soustavy  Převzat z [11]  . . . . .             | 21 |
| 3.3  | Normalizovaná řada střídavých napětí  Převzat z [9]  . . . . .                   | 22 |
| 3.4  | Schéma přenosové soustavy ČR  Převzat z [11]  . . . . .                          | 22 |
| 3.5  | Území působnosti distribučních společností ČR  Převzat z [11]  . . . . .         | 23 |
| 3.6  | Graf zatížitelnosti transformátoru  Převzat z [10]  . . . . .                    | 27 |
| 3.7  | Graf ztrát transformátoru v závislosti na zatížení  Převzat z [11]  . . . . .    | 28 |
|      |  |    |
| 4.1  | Špičkové denní zatížení z transformátoru Černice (září až prosinec 2014) . .     | 34 |
| 4.2  | Špičkové denní zatížení z transformátoru Plzeň Sever (září až prosinec 2014)     | 35 |
| 4.3  | Špičkové denní zatížení z transformátoru Černice v roce 2014 . . . . .           | 35 |
| 4.4  | Špičkové denní zatížení z transformátoru Plzeň Sever v roce 2014 . . . . .       | 36 |
| 4.5  | Celkové denní zatížení z transformátoru Černice (září až prosinec 2014) . .      | 37 |
| 4.6  | Celkové denní zatížení z transformátoru Plzeň Sever (září až prosinec 2014)      | 38 |
| 4.7  | Celkové denní zatížení z transformátoru Černice v roce 2014 . . . . .            | 38 |
| 4.8  | Celkové denní zatížení z transformátoru Plzeň Sever v roce 2014 . . . . .        | 39 |
| 4.9  | Denní diagram zatížení z 10. 11. 2014 z transformátoru Černice . . . . .         | 40 |

|      |   |    |
|------|---|----|
| 4.10 | Denní diagram zatížení z 10. 11. 2014 z transformátoru Plzeň Sever . . . .  | 41 |
| 5.1  | Ukázka detailu špičkového denního zatížení z transformátoru Černice . . . . | 44 |

# Seznam tabulek

|     |   |    |
|-----|---|----|
| 5.1 | Error špičkového denního zatížení . . . . .                       | 42 |
| 5.2 | Error celkového denního zatížení . . . . .                        | 43 |
| 5.3 | Error hodinového zatížení pro transformátor Černice . . . . .     | 43 |
| 5.4 | Error hodinového zatížení pro transformátor Plzeň Sever . . . . . | 44 |

# Seznam symbolů a zkratek

|                                      |  |
|--------------------------------------|--|
| $w$ .....                            | váha synaptického spojení mezi neurony                               |
| $\mathbf{w}$ .....                   | vektor vah synaptického spojení mezi neurony                         |
| $x$ .....                            | vstup neuronu  |
| $\mathbf{x}$ .....                   | vstupní vektor sítě  |
| $o$ .....                            | výstup neuronu   |
| $\mathbf{O}$ .....                   | výstupní vektor sítě   |
| net .....                            | přenosová funkce   |
| $m$ .....                            | počet neuronů  |
| $h(x)$ .....                         | neznámá spojitá funkce   |
| $H(\mathbf{x}, \mathbf{w})$ .....    | aproximace funkce $h(x)$   |
| $\rho(\mathbf{d}, \mathbf{o})$ ..... | funkce upravující hodnotu vah  |
| $\mathbf{d}$ .....                   | vektor skutečných hodnot poskytnutých "učitelem"                     |
| $\Phi$ .....                         | střídavý magnetický tok [Wb]   |
| $\Phi_h$ .....                       | hlavní složka střídavého mag. toku [Wb]                              |
| $\Phi_\sigma$ .....                  | rozptylová složka střídavého mag. toku [Wb]                          |
| $u_i$ .....                          | indukované napětí [V]  |
| $U_i$ .....                          | efektivní hodnota indukovaného napětí [V]                            |
| $u_i$ .....                          | indukované napětí [V]  |
| $\Delta P$ .....                     | ztráty v transformátoru [W]  |
| $\Delta P_0$ .....                   | ztráty v transformátoru naprázdno [W]                                |
| $\Delta P_K$ .....                   | ztráty v transformátoru nakrátko [W]                                 |
| $\Delta P_{KN}$ .....                | ztráty v transformátoru nakrátko při průchodu nominálním proudem [W] |
| $\Delta P_{Fe}$ .....                | ztráty v železe [W]  |
| $\Delta P_j$ .....                   | Joulovy ztráty [W]   |
| $\Delta P_d$ .....                   | přídavné ztráty [W]  |
| $\Delta P_{Fev}$ .....               | ztráty vířivými proudy [W]   |
| $\Delta P_{Feh}$ .....               | ztráty hysterézní [W]  |
| $R$ .....                            | odpor vinutí [ $\Omega$ ]  |
| $I$ .....                            | proud [A]  |
| $I_N$ .....                          | nominální proud [A]  |
| $U$ .....                            | napětí [V]   |

|           |   |
|-----------|---|
| y,Y ..... | označení zapojení vinutí do hvězdy        |
| d,D ..... | označení zapojení vinutí do trojúhelníku  |
| z,Z ..... | označení zapojení vinutí do lomené hvězdy |
| p .....   | převod transformátoru                     |
| N .....   | počet závitů                              |
| nn .....  | nízké napětí                              |
| vn .....  | vysoké napětí                             |
| vvn ..... | velmi vysoké napětí                       |

# Kapitola 1

## Úvod

Znalost velikosti odběru elektrické energie je velmi cenná informace. Kdybychom uměli tuto informaci předvídat, věděli bychom, kolik je zapotřebí elektrické energie vyrobit, v jaký den v týdnu či v jaký čas očekávat největší, resp. nejnižší zatížení. Tuto informaci můžeme získat pomocí adaptace umělé neuronové sítě. Neuronová síť je ve velké části využívána v umělé inteligenci. V dnešní době je umělá inteligence využívána téměř ve všech oborech a je nezbytnou součástí pro vývoj nových technologií.

Tato práce se zabývá základní aplikací neuronové sítě na data z distribučního transformátoru pro získání možné predikce zatížení distribučního transformátoru v následujících měsících, týdnech či dnech. V druhé kapitole této práce jsou popsány základní vlastnosti umělých neuronových sítí a možnost použití softwaru MATLAB pro simulaci predikce pomocí neuronové sítě. Třetí kapitola popisuje základní principy elektrického stroje pro transformaci napětí distribučního transformátoru a hospodárnosti jeho zatěžování v distribuční síti. Také je zde popsána elektrizační soustava a to především distribuční soustava, ve které se tento transformátor nachází. Ve čtvrté kapitole už je popsáno využívání neuronové sítě v programu MATLAB na reálná data z distribučního transformátoru. Úprava vstupních a cílových dat pro síť a samotná simulace výstupních dat z neuronové sítě pro nadcházející měsíce, týdny či dny. Pátá kapitola slouží pro porovnání výsledků z modelů se skutečností a jsou zde popsány přesnosti jednotlivých predikcí zatížení.

# Kapitola 2

## Umělá neuronová síť

### 2.1 Úvod do teorie neuronové sítě

Lidský mozek funguje zcela odlišnými způsoby než dnes známé digitální počítače. Přednost počítačů spočívá v extrémně rychlém a přesném zpracování instrukcí, na něž byly naprogramovány. Oproti tomu, lidský informační systém je složen z přepínání neuronů rychlostí přibližně milionkrát pomalejší, než je rychlost průběhu počítačových procesů. Lidé jsou však mnohem účinnější při řešení některých složitých úkolů, jako je například porozumění řeči. Nejenom lidé, ale také zvířata mohou zpracovávat vizuální informace lépe než nejrychlejší počítače. [1]

V současnosti se pracuje na otázce, může-li technologie těžit z výpočetních schopností organismů. Umělé neuronové sítě jsou postavené na základě pochopení a využití potenciálních funkčních podobností mezi lidskými a umělými systémy pro zpracování informace. Cílem je realizace masivně paralelně propojených systémů, které by mohly zpracovávat informace s účinností srovnatelnou s účinností mozku. [1]

Umělé neuronové sítě jsou fyzické buněčné systémy, které mohou získávat, ukládat a využívat získané znalosti. Klasický princip programovatelné výpočetní techniky spočívá v rozhodovacích pravidlech a algoritmech ve formě počítačových programů. U neuronových sítí jsou též tyto algoritmy a programové řízení využívány a to zejména v pravidlech učení a vyvolání výstupní informace neuronové sítě. Algoritmy a programové řízení není úplně stejné jako u digitálních počítačů, jelikož neuronová síť umí v závislosti na reakci vstupní informace měnit svoji strukturu. [1]

Schopnost neuronové sítě vykonávat výpočty je založena na reprodukovatelnosti flexibility a síly lidského mozku pomocí umělých prostředků. Výpočet sítě je prováděn hustou sítí výpočetních uzlů a spojení. Základní stavební prvky neuronových sítí jsou nazývány umělé neurony. Neurony fungují, jako součtové a nelineární spoje. V některých případech mohou být považovány za prahové jednotky, které jsou překlopeny do jiného stavu, jakmile vstup dosáhne určité prahové hodnoty (biasu). Neurony obvykle pracují paralelně a jsou uspořádány ve vrstvách, je zde i možnost zpětnovazebního spojení ve vrstvě nebo v sousední vrstvě. Tyto vrstvy tvoří pravidelnou architekturu, což je jejich základní

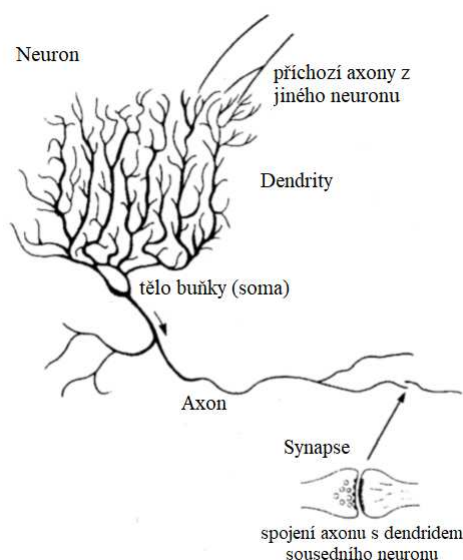


charakteristika. Každé spojení má svoji sílu, která je vyjádřena numerickou hodnotou nazývanou váha, kterou lze měnit. Další charakteristickou vlastností je dynamika sítě. Některé sítě poskytují okamžité odezvy, ostatní potřebují čas, aby reagovaly a jsou tedy charakterizovány chováním v časové oblasti. [1]

Aby byla neuronová síť schopna produkovat požadované výstupy, musí být nejprve trénována (naučena). Existuje několik trénovacích režimů, kterým může být síť podrobena. Každý trénovací režim mění váhy neuronů podle odlišných kritérií. V tomto se neuronové sítě liší od počítačů, které jsou naprogramovány na provádění specifického úkolu. Neuronová síť se natrénováním učí novým vzorům a novým funkčním závislostem. Uživatel pracující s neuronovou sítí neudává algoritmus, který by měl výpočetní uzel provádět. Místo toho volí, jaká by byla nejlepší architektura sítě, přenosové funkce a volí režim trénování. [1]

## 2.2 Biologický podtext

Svůj základ našly umělé neuronové sítě bezpochyby v biologických neuronových systémech. Nicméně shoda mezi umělými a reálnými neurálními systémy je velmi slabá, proto mezi architekturami a schopnostmi umělých a přírodních sítí existují velké rozdíly. [1]




**Obrázek 2.1:** Model biologického neuronu [Převzato z [1]]

Kdybychom studovali lidský mozek, našli bychom zde až  $10^{11}$  výpočetních prvků nazývaných neurony. Tento nespočet prvků mezi sebou komunikuje pomocí propojené sítě složené z axonů a synapsí. Na jeden neuron vychází téměř  $10^4$  synapsí. Komunikace probíhá prostřednictvím elektrických impulsů. Z této úvahy můžeme lidský mozek považovat za hustě propojenou elektrickou spínací síť. Vstup do sítě zprostředkovávají smyslové receptory pomocí stimulů, též ve formě elektrického impulsu. Stimuly jsou vysílány jak

zevnitř těla tak ze smyslových orgánů. Zpracováním vstupní informace centrálním nervovým systémem jsou řízeny efektory, které dávají tělu podněty formou různých akcí. Efekторы řídí motorické orgány, které jsou sledovány centrální nervovou soustavou pomocí zpětných vazeb, která kontroluje jejich činnost. Celková struktura nervové soustavy má tedy hodně společných vlastností s řízením systému s uzavřenou smyčkou. [1]

Základním stavebním kamenem nervové soustavy, jak již bylo řečeno, je neuron, jehož schematická podoba je vyobrazena na obr. 2.1. Neuron se skládá ze tří hlavních částí: tělo buňky (nazývané soma), axon a dendrit. Informace se do neuronu dostává pomocí dendritu, což je seskupení tenkých vláken kolem těla neuronu. Dendrit je spojen s axonem (jiného neuronu), který nese výstupní informaci z jiného neuronu. Konec axonu se jen téměř dotýká dendritu a toto spojení je nazýváno synapse. [1]

## 2.3 Obecný model umělého neuronu



Obrázek 2.2: Obecný model neuronu [Převzato z [1]]

Obr. 2.2 je modelem základní představy o umělém neuronu. Konkrétní umělé neuronové systémy a výpočetní algoritmy využívají různých modelů umělých neuronů. Pro pochopení myšlenky práce neuronu, je v tomto modelu využito mnoho zjednodušení. Váhy a prahové hodnoty neuronu jsou pevně stanoveny a jejich hodnota je neměnná. Základem modelu neuronu je zpracovávací prvek, do kterého jsou přiváděny synaptickými připojeními vstupní hodnoty. Každá vstupní hodnota má svoji určitou váhu, kterou je násobena přichozí informace. Model má jen jeden výstup. Tok signálu v modelu je naznačen šipkami a je jednosměrný. Přivedené informace jsou integrovány do neuronu a je stanovena primitivní funkce, též nazývána jako aktivační nebo přenosová funkce:

$$O = f\left(\sum_{i=1}^n w_i x_i\right) \quad (2.1)$$

kde  $\mathbf{w}$  je vektor vah definovaný jako:

$$\mathbf{w} = [w_1 \ w_2 \ \dots \ w_n]^t \quad (2.2)$$

a  $\mathbf{x}$  je vektor vstupů:

$$\mathbf{x} = [x_1 \ x_2 \ \dots \ x_n]^t \quad (2.3)$$


Všechny vektory definované výše jsou sloupcové vektory tedy zapsané jako řádkové vektory a transponované. Každý uzel (neuron) si poté můžeme představit jako primitivní funkci, která je schopna transformovat jeho vstup na přesně definovaný výstup. Umělá neuronová síť je poté sítí primitivních funkcí. Existují různé primitivní přenosové funkce a vzory propojení ve kterých se modely odlišují. [1][2]

### 2.3.1 Přenosové funkce

Pro zjednodušení si zavedeme proměnnou  $net$ , která je argumentem přenosové funkce a je definována jako skalární součin vektoru vah a vstupního vektoru.

$$\mathbf{net} = \mathbf{w}^t \mathbf{x} \quad (2.4)$$

Argument přenosové funkce udává, jestli je neuron v pasivním nebo aktivním stavu. Je-li argument přenosové funkce nižší než práh, je neuron pasivní. Proměnná  $net$  je vytvořena zpracovávacím prvkem neuronu, jak je patrné z rov. 2.1. Následně na to, pomocí přenosové funkce, provede neuron nelineární funkci  $f(net)$ . Existuje několik typů přenosových funkcí.



Obrázek 2.3: Přenosové funkce. [Převzato z [1]]

Na obrázku 2.3 jsou znázorněny základní přenosové funkce ( a) hard-lim unipolární, b) funkce rampy, c) unipolární sigmoidální, d) bipolární sigmoidální).

$$f(net) = \frac{2}{1 + e^{-net}} - 1 \quad (2.5)$$

$$f(net) = \operatorname{sgn}(net) = \begin{cases} +1, & net > 0 \\ -1, & net < 0 \end{cases} \quad (2.6)$$

Přenosová funkce 2.5 a 2.6 se nazývají bipolární, jelikož mohou produkovat jak kladné tak záporné hodnoty. Posouváním bipolárních přenosových funkcí můžeme vytvořit unipolární přenosové funkce 2.7 a 2.8.

$$f(net) = \frac{1}{1 + e^{-net}} \quad (2.7)$$

$$f(net) = \begin{cases} 1, & net > 0 \\ 0, & net < 0 \end{cases} \quad (2.8)$$

Funkce 2.5 a 2.7 jsou takzvané soft-lim přenosové funkce, neboli sigmoidální přenosové funkce. Jejich výstupní hodnoty jsou transformovány mezi hodnoty (-1,1) nebo (0,1). Funkce 2.6 a 2.8 jsou hard-lim přenosové funkce. Výstup je transformován buď na 0 nebo 1, nebo -1 a 1. Jako další důležitá přenosová funkce může být funkce rampy, též nazývaná lineární funkce. [1]

## 2.4 Modely umělých neuronových sítí


Výstupy neuronů jsou pomocí synaptických spojení s určitou vahou propojeny s dalšími neurony včetně sebe samých. Takový celek o několika spojených neuronech tvoří neuronovou síť. Různé druhy architektur neuronových sítí slouží k řešení různých úkolů. Liší se síť, která umí rozpoznávat obrazce a liší se síť, která slouží například k predikci nebo pro proložení grafu. Existuje mnoho způsobů, jak neuronovou síť poskládat. Mezi nejdůležitější architektury patří:

- jednovrstvá dopředná síť
- vícevrstvá dopředná síť
- rekurentní síť

[1] [3]

### 2.4.1 Jednovrstvá dopředná síť

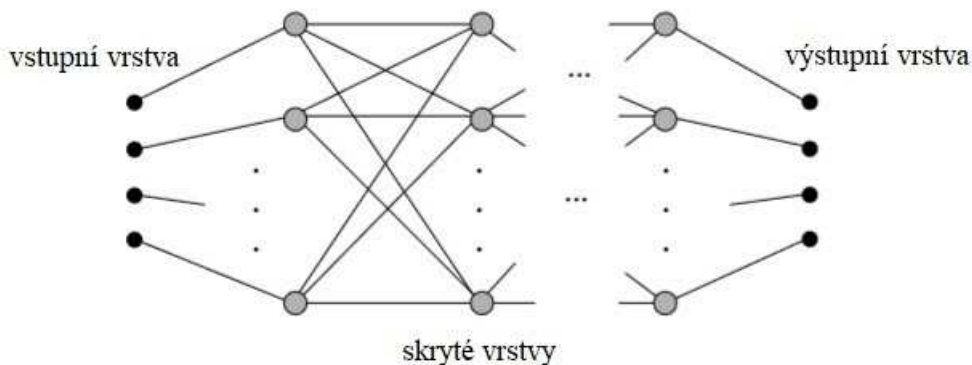
Tuto síť si můžeme představit jako jednu vrstvu  $m$  neuronů do kterých vstupuje  $x_n$  vstupů. Každý vstup je přiveden se svojí váhou  $w_{ij}$  do každého neuronu. Každý neuron v této vrstvě má jeden výstup. Tyto výstupy tvoří výstupní sloupcový vektor  $\mathbf{o}$ . Taková jednovrstvá struktura je zobrazena na obr. 2.4. [1] [3]



Obrázek 2.4: Jednovrstvá dopředná síť |Převzato z [1]|

### 2.4.2 Vícevrstvá dopředná síť

Podle názvu je patrné, že tato síť obsahuje více vrstev. První vrstva se nazývá vstupní vrstva a neprovádí žádný výpočet, proto tuto vrstvu nepočítáme. Na konci sítě je vrstva výstupní, ze které je produkován výstup. Mezi vrstvou vstupní a výstupní může být umístěna jedna, nebo několik vrstev skrytých.




Obrázek 2.5: Vícevrstvá dopředná síť |Převzato z [2]|

Výkon sítě a její schopnost mohou být ovlivněny počtem skrytých vrstev. V takovéto

síti jsou výstupy jakékoli vrstvy vstupem do vrstvy následující. Počet, kolik má každý neuron ve vrstvě vstupů, určuje počet neuronů ve vrstvě předešlé.[1] [3]

### 2.4.3 Rekurentní síť

Rekurentní síť může být utvořena například sítí dopřednou jednovrstvou. Výstupy z neuronů jsou přiváděny skrze zpožďovací blok zpět na vstupy neuronů. Smyslem uzavírání zpětnovazebních smyček je umožnit řízení výstupu pomocí samotných výstupních hodnot. Ve zpětnovazební smyčce jsou zavedeny zpožďovací prvky viz. obr. 2.6. [1]



Obrázek 2.6: Rekurentní síť [Převzato z [2]]

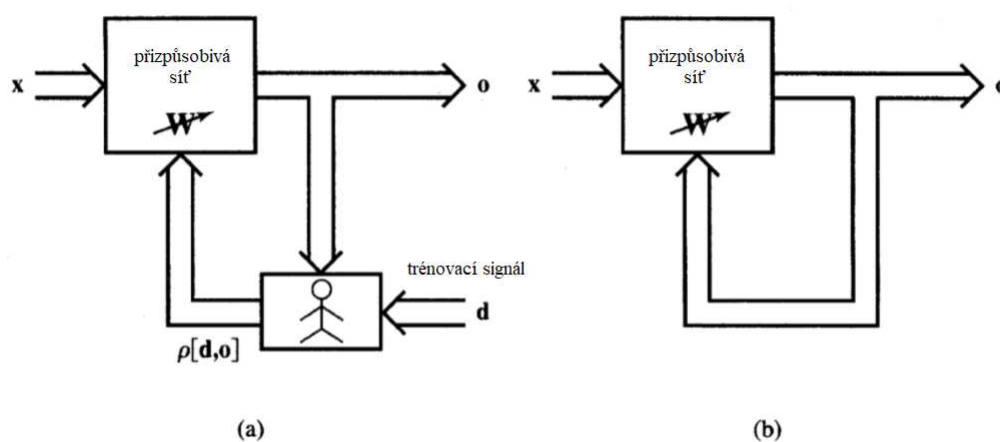
## 2.5 Učení neuronové sítě

Pojem učení neuronové sítě, nebo též nazýváno trénování sítě je velmi lehké vysvětlitelné. Stejně tak jako lidé neumějí všechno, neumí nic nenaučená síť. Abychom byli schopni vykonávat nějakou dovednost a disponovali jistou schopností, musíme se nejdříve tuto schopnost naučit prostřednictvím zkušeností. Vzdělání je obecně trvalá změna chování způsobená zkušenostmi. Učení u lidí a zvířat je těžko pozorovatelný proces. Nemůžeme ho sledovat přímo a sledujeme ho tedy jen jako změnu ve výkonnosti. U neuronových

sítí je proces učení snadněji zachytitelný. Jsme schopni vidět každý krok učení ve vztahu příčina - následek. Aby síť byla schopná vykonávat svoji úlohu, musíme ji tedy předložit a nechat nastudovat soubor vstupů a jím příslušejících výstupů ze souboru příkladů. [1]

Učení sítě můžeme přirovnat k aproximaci neznámé spojité funkce  $h(x)$  o více proměnných jinou funkcí  $H(\mathbf{w}, \mathbf{x})$ . Hledaná funkce má dva parametry, vstupní vektor  $\mathbf{x}$  a vektor vah  $\mathbf{w}$ . Podstata učení je nalezení takového vektoru vah  $\mathbf{w}$ , který by poskytoval nejlepší možnou aproximaci naší neznámé funkce, na základě natrénování na souboru příkladů. Míra kvality naučení neuronové sítě je potom funkce vzdálenosti  $\rho[H(\mathbf{w}, \mathbf{x}), h(x)]$  mezi neznámou funkcí  $h(x)$  a  $H(\mathbf{w}, \mathbf{x})$ . [1]

Učení sítě je možné provádět dvěma způsoby. Učení s učitelem nebo učení bez učitele. Učení s učitelem chápeme jako zavedení zpětné vazby od učitele. Na každý vložený vstup je poskytnuta odpověď  $\mathbf{d}$  od učitele. Jak již bylo zavedeno,  $\rho[\mathbf{d}, \mathbf{o}]$  je vzdálenost mezi skutečnou a požadovanou hodnotou a určuje chybu sítě. Tato chyba slouží ke korekci síťových parametrů, kterými mohou být například úprava vah  $\mathbf{w}$ , aby byla chyba co nejmenší. Pro tento způsob učení sítě je vyžadována sada trénovacích dat, obsahující vstupní a jím příslušející výstupní hodnoty. Tento způsob učení je blokově naznačen na obr. 2.7 (a). Učení bez učitele obr. 2.7 (b) se liší v tom, že požadovaná odpověď na vstupní hodnotu není známa. Chybové informace nemůžeme tedy využít pro zlepšení chování sítě. Pozorují se odpovědi na vstupy a síť si je seskupuje na základě jejich podobnosti. [1] [3]



**Obrázek 2.7:** Blokový diagram způsobů učení: (a) s učitelem, (b) bez učitele |Převzato z[1]|

## 2.6 Využití programu Matlab pro simulaci neuronové sítě

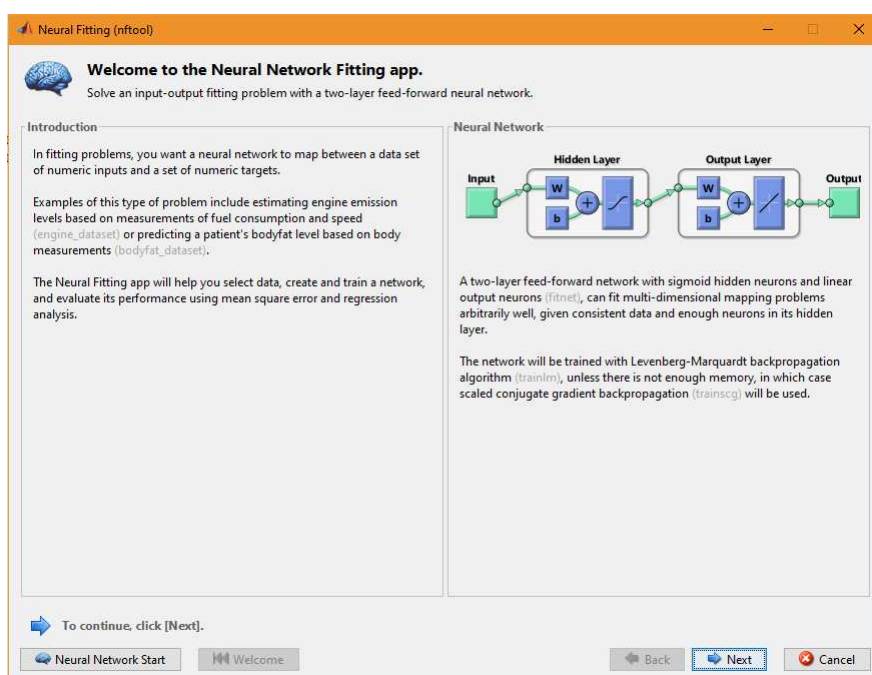
Matlab je výpočetní programovatelné prostředí, které lze využívat pro celou řadu problémů. Je schopen počítat s maticemi, vytvářet všechny různé grafy, ať už 2D nebo 3D, provádět počítačovou simulaci, analýzu a prezentaci dat. Je zde možné i vytvořit aplikaci včetně uživatelského prostředí. Název Matlab je odvozen od slov MATrix a LABoratory.

Už z názvu vyplývá, že se zabývá hlavně maticemi. Veškeré objekty v Matlabu jsou považovány za matice neboli prvky pole. Matice nemusejí být jenom čísla, ale mohou to být též proměnné nebo složitější struktury (např. obrázky). Matlab se hodí opravdu do všech odvětví techniky, matematiky či ekonomie. Jeho výkonost je ještě posílena o různé tzv. "toolboxy", které usnadňují řešení problémů pomocí předpřipravených aplikací. [4] [5]

V Matlabu je možné vytvářet mnoho různých typů neuronových sítí různými způsoby pomocí Neural Network Toolbox. Pro zadaný úkol se v této práci budu zabývat pouze problémem, který je řešen pomocí "fitting a function". Pro základní představu, k čemu je "fitting" dobrý, si představme, že bychom chtěli vytvořit síť, která by byla schopna odhadnout cenu nemovitosti, na základě informací o ní. Měli bychom například 500 domů, o kterých bychom věděli jejich informace (poloha, vzdálenost od města, hlučnost, rok výstavby, velikost, atd.) a také jejich cenu. To znamená, že informace o nemovitosti by byly vstupní hodnoty a její cena by byla hodnotou výstupní. Síť by se natrénovala a kdybychom chtěli vědět cenu nemovitosti, kterou bychom prodávali, stačilo by jen zadat potřebné vstupní informace a síť by na základě těchto informací v porovnání s cenami předešlých nemovitostí byla schopna predikovat její cenu. [4] [5]

Tento problém je v Matlabu možné vytvořit třemi způsoby. Využít příkazový řádek, Graphical User Interface (GUI) nebo Neural Network Fitting Tool GUI. V této práci se budu zabývat pouze základní aplikací neuronové sítě a to pomocí Neural Network Fitting Tool GUI. [4]

## 2.6.1 Neural Network Fitting Tool GUI



Obrázek 2.8: Neural Network Fitting Tool GUI



Popis Neural Network Fitting Tool GUI si ukážeme na jednoduchém příkladě, kdy naučíme neuronovou síť logickou funkci AND.

Pro otevření Neural Network Fitting Tool GUI použijeme příkaz, který zadáme do Command Window:

```
>> nftool
```

Po zadání se otevře startovací okno (obr. 2.8), na kterém vidíme, co tato funkce umí a přibližnou architekturu sítě. V příkazovém řádku si vytvoříme vstupní a cílové hodnoty, na kterých budeme síť trénovat. Proměnná *input* představuje hodnoty dvou vstupů ( $Q_1$  a  $Q_2$ ), které vstupují do logického členu. Proměnná *target* představuje výstupní hodnoty logického členu.

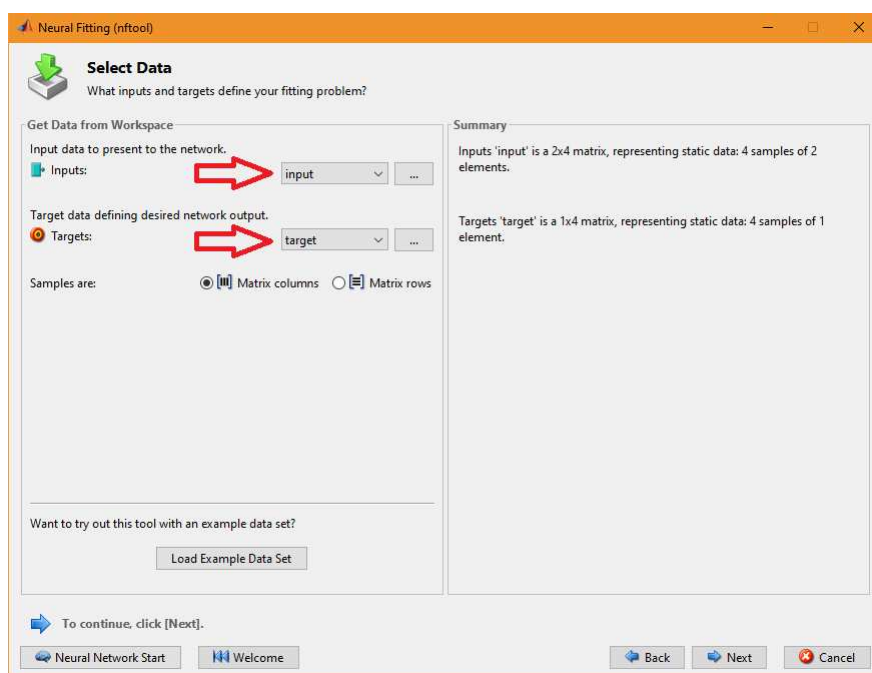
```
>> input= [0 0 1 1 ; 0 1 0 1]
```

```
input =  
      0      0      1      1  
      0      1      0      1
```

```
>> target= [0 0 0 1]
```

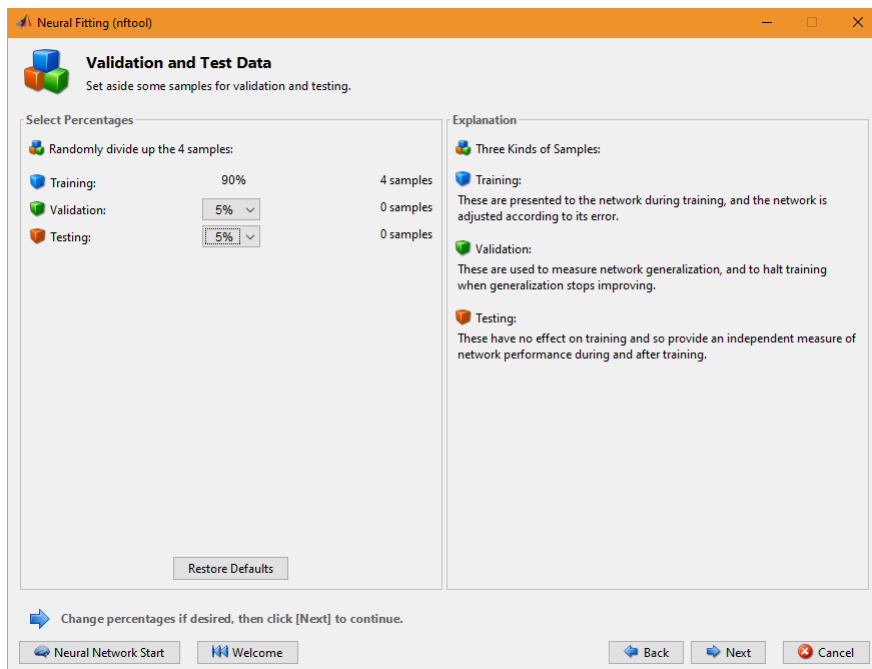
```
target =  
      0      0      0      1
```

V dalším okně tyto hodnoty importujeme pomocí rozbalovacího okna (obr. 2.9).



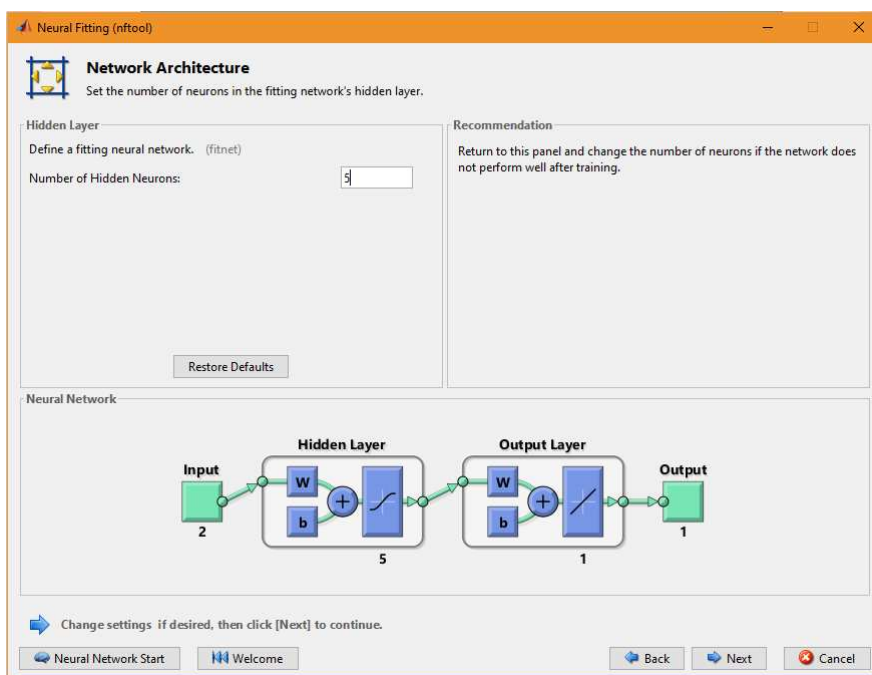
Obrázek 2.9: Vybrání dat pro neuronovou síť

Dále můžeme nastavit, kolik dat bude určeno k natrénování sítě, kolik k ověření pro zastavení trénování a kolik pro testování a určení chyby (obr. 2.10). V tomto jednoduchém příkladě, nastavíme všechny hodnoty pro natrénování, jelikož se jedná o snadnou úlohu a chyba nás nezajímá.



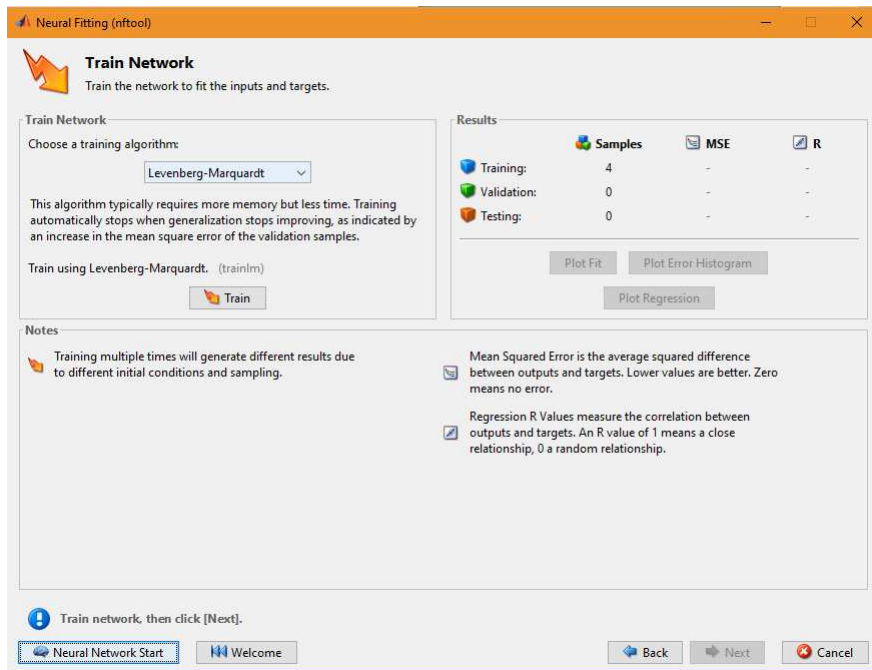
Obrázek 2.10: Rozdělení dat do skupin

V dalším okně zadáme počet neuronů ve skryté vrstvě (obr. 2.11). Počet volíme náhodně. Přibližně by to mělo být tolik, kolik řádku má vstupní matice. Čím více neuronů

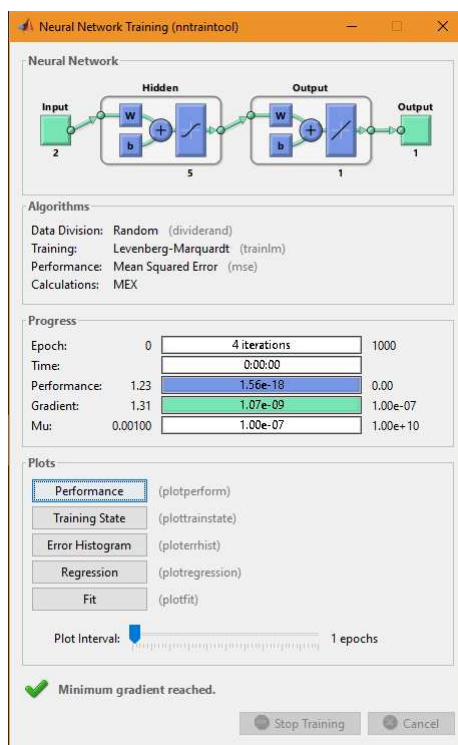


Obrázek 2.11: Zadání počtu neuronů ve skryté vrstvě

bude ve skryté vrstvě, tím déle může trvat učení sítě. Bude-li počet neuronů příliš velký, může nastat přetrénování sítě a síť bude produkovat nesmyslné hodnoty. Také je zde možné vidět architekturu neuronové sítě s počty neuronů a použitých přenosových funkcí v jednotlivých vrstvách.



Obrázek 2.12: Spuštění trénování sítě

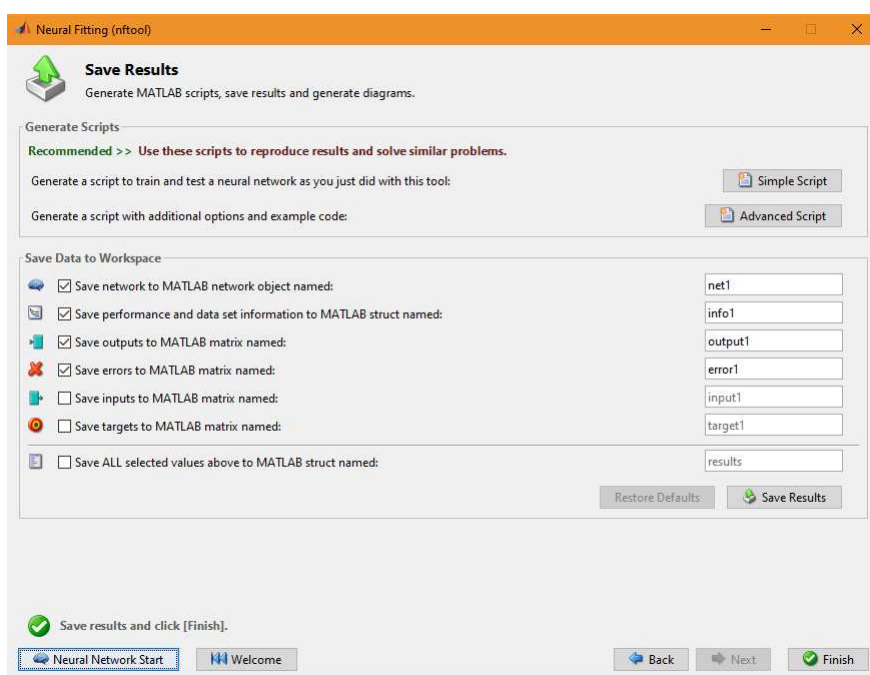


Obrázek 2.13: Průběh trénování sítě

Nyní je už síť vytvořena a je zapotřebí ji natrénovat. V rozbalovacím okně můžeme změnit trénovací algoritmus (obr. 2.12). My budeme používat algoritmus Levenberg-Marquardt. Tento algoritmus potřebuje sice více paměti, ale k trénování postačí méně času. Trénování se automaticky zastaví, když je indikováno zvyšování chyby MSE (mean square error) u validačních dat. Už stačí jen kliknout na tlačítko "Train".

Při trénování sítě vyskočí nové okno (obr. 2.13), na kterém vidíme průběh tréninku. Jsou zde počty provedených iterací, uběhlý čas, atd.

V posledním okně (obr. 2.14) je možné nechat vygenerovat jednoduchý, nebo pokročilý skript, ve kterém je pak možné měnit počty neuronů ve skryté vrstvě, algoritmy pro trénování, výběr trénovacích dat, atd. Při nespokojenosti s výsledky natrénování sítě je možné spustit trénování znovu.



Obrázek 2.14: Generování skriptů a výsledků

Nyní je síť natrénovaná a připravená k dalšímu použití. Pro simulaci sítě použijeme příkaz "sim(objekt,vstupní hodnoty)". Vytvoříme vstupní matici, která prezentuje vždy dvě vstupní hodnoty pro logický člen AND. Jako vstupní hodnoty nyní použijeme náhodně zvolená čísla (0 nebo 1). Podle teoretického předpokladu by výstup logické funkce AND měl být logická 1, když na vstupu budou dvě logické 1 nebo logická 0, když na vstupu bude něco jiného.

```
>> input= [0 0 1 1 0 0 1 1 0 0 ; 0 1 0 1 0 0 1 1 0 0 ]
```

```
input =
```

```
    0    0    1    1    0    0    1    1    0    0  
    0    1    0    1    0    0    1    1    0    0
```

```
>> output=sim(net,input)
```

```
output =
```

```
-0.00  0.00  0.00  1.00 -0.00 -0.00  1.00  1.00 -0.00 -0.00
```

# Kapitola 3

## Hospodárné zatěžování transformátoru v distribuční síti

### 3.1 Transformátor

Transformátor je elektrický netočivý stroj, jehož přední schopností je měnit velikost napětí a proudu. Pro přenos elektrické energie je vyžadováno, aby přenášené napětí bylo co nejvyšší a proud co nejnižší z důvodu menších Joulových ztrát na vedení a tím možnosti přenášení vyšších výkonů. Pro rozvod elektrické energie se naopak napětí snižuje na úroveň přijatelnou pro rozvod elektrické energie a pro správnou funkci elektrických spotřebičů. Transformátor není schopný transformovat výkon, pouze napětí, proud a impedanci. Též může transformátor sloužit jako ochranné zařízení a to ve smyslu galvanického oddělení, například měřicí transformátory. Transformátory se podle účelu v elektroenergetice dělí na:

- **Transformátor blokový** - transformátor je v sérii s alternátorem. Tyto transformátory jsou umístěny v elektrárnách, které nemají napájení vlastní spotřeby přímo na alternátorovém napětí a musí tedy zde být umístěn dvouvinuťový nebo trojvinuťový transformátor, z hlediska konstrukce může být buď jednofázový nebo třífázový.
- **Transformátor spojovací** - takovéto transformátory se používají pro spojování dvou různých elektrických sítí o různých napěťových hladinách. Při spojování (transformaci) sítě  $v_{vn}/v_n$  jsou využívány třífázové transformátory. U soustav  $v_{vn}$  jsou již primárně využívány tři transformátory jednofázové a jeden záložní. Též mohou být použity autotransformátory.
- **Transformátory průmyslové distribuční nebo vlastní spotřeby** - jsou třífázové. Jejich výstupní napětí je buď  $v_n$  nebo  $nn$ .
- **Transformátory izolační** - díky galvanickému oddělení chrání výrobní zdroje od venkovních vedení před atmosferickým přepětím. Také mohou sloužit k omezení zkratových proudů. Mají převod 1:1.

Transformátory se vyrábějí pro různá napětí od  $\mu\text{V}$  a zlomků VA pro požití ve slaboproudé technice, až po hodnotu napětí stovek kV a výkonu MVA pro přenosy nejvyšších výkonů. [7] [8] [9]

### 3.1.1 Princip činnosti

Činnost transformátoru je založena na Maxwell - Faradayova zákoně o indukovaném napětí. Primární a sekundární vinutí je navinuto na uzavřeném feromagnetickém jádře, které tvoří magnetickou vazbu mezi primárním a sekundárním vinutí. Připojením primárního vinutí ke zdroji střídavého napětí začne vinutím procházet proud  $i_t$ , který vybudí střídavý magnetický tok  $\Phi_1$ . Tento tok obsahuje dvě složky. Složka hlavní  $\Phi_{1h}$ , která zabírá se sekundárním vinutí a uzavírá se feromagnetickým jádrem a složka rozptylová, neboli rozptylový magnetický tok  $\Phi_{1\sigma}$ , který se nepodílí na indukování v sekundárním vinutí, jelikož se uzavírá jen kolem vinutí, jímž prochází proud, který jej budí. [7]

$$\Phi_1(t) = \Phi_{1h}(t) + \Phi_{1\sigma}(t) \quad (3.1)$$

Vlivem připojení zátěže na sekundární vinutí, začne sekundárním vinutí procházet proud  $i_2$ , který vyvolá svůj magnetický tok  $\Phi_2$ .

$$\Phi_2(t) = \Phi_{2h}(t) + \Phi_{2\sigma}(t) \quad (3.2)$$

Pro výsledný magnetický tok, uzavírající se feromagnetickým jádrem, potom platí:

$$\Phi_h(t) = \Phi_{1h}(t) + \Phi_{2h}(t) \quad (3.3)$$

Vnitřní indukované napětí je výsledkem indukce výsledného magnetického toku  $\Phi_h(t)$ :

$$u_{i1} = N_1 \frac{d\Phi_h}{dt} = \frac{d\Psi_1}{dt} \quad (3.4)$$

$$u_{i2} = N_2 \frac{d\Phi_h}{dt} = \frac{d\Psi_2}{dt} \quad (3.5)$$


Výsledný magnetický tok je harmonického průběhu, a proto je možno zapsat, že pro indukované napětí platí:

$$u_i = \frac{d\Psi}{dt} = \frac{d}{dt}(N\Phi_m \sin\omega t) = N\Phi_m \omega \cos\omega t \quad (3.6)$$

Efektivní hodnotu indukovaného napětí lze zapsat jako:

$$U_i = \frac{2\pi f}{\sqrt{2}} N\Phi = 4,44fN\Phi \quad (3.7)$$

[7]



Obrázek 3.1: Schématické znázornění 1-fázového transformátoru [Převzato z [7]]

### 3.1.2 Ztráty transformátoru

Jako každý elektrický stroj, není ani transformátor ideální stroj, který by vykonával svoji schopnost bez ztrát. Celkové ztráty se skládají ze ztrát naprázdno  $\Delta P_0$ , které nejsou závislé na velikosti zatížení a ztrát nakrátko  $\Delta P_K$ , které na velikosti zatížení závislé jsou. [8]

$$\Delta P = \Delta P_0 + \Delta P_K = \Delta P_{Fe} + \Delta P_j + \Delta P_d \quad (3.8)$$

Ztráty naprázdno se skládají ze ztráty v železe  $\Delta P_{Fe}$  a Jouleových ztrát ve vinutí. Při měření  $\Delta P_0$  je transformátor v chodu naprázdno a vinutím prochází jen velmi malý proud naprázdno, jehož velikost činí přibližně jen 10 % proudu nominálního. Z tohoto důvodu Jouleovy ztráty při chodu naprázdno můžeme zanedbat a ztráty naprázdno se stanou jen ztráty v železe. [8]

$$\Delta P_{Fe} = \Delta P_{Fev} + \Delta P_{Feh} \quad (3.9)$$

Ztráty v železe se skládají ze ztrát vířivými proudy  $\Delta P_{Fev}$ , úměrných kvadrátu magnetické indukce a kvadrátu frekvence a ztrát hysterézních  $\Delta P_{Feh}$ , úměrných též kvadrátu magnetické indukce a frekvenci. Vytvořením jádra transformátoru z několika poskládaných tenkých plechů a přidáním křemíku do jejich materiálu, který bude snižovat jejich vodivost jsme schopni ztráty vířivými proudy omezit. Omezení ztrát hysterézních se docílí použitím plechů, které mají úzkou hysterézní smyčku. [7]

Do ztrát nakrátko patří přídavné ztráty  $\Delta P_d$  a Jouleovy ztráty ve vinutí  $\Delta P_j$ . Přídavné ztráty jsou zapříčiněny skinefektom a vířivými proudy v dílech celého transformátoru. Jouleovy ztráty jsou ztráty na primárním a sekundárním vinutí způsobené průchodem proudu. Zjišťují se z chodu nakrátko a platí pro ně:

$$\Delta P_j = m(R_1 + R_2)I_1^2 \quad (3.10)$$

kde  $m$  je počet fází a odpory  $R_1$  a  $R_2$  jsou odpory primárního a sekundárního vinutí. [7] [6]



### 3.1.3 Účinnost transformátoru

Účinnost elektrického stroje je obecně poměrem vytvořeného výkonu ku přivedenému příkonu. Jak již bylo řečeno, transformátor není bezeztrátový stroj, čili nemá 100 % účinnost. Průchodem proudu transformátorem vznikají ztráty, které byly popsány v části 3.1.2 a úbytek napětí na transformátoru. Vlivem ztrát a úbytku napětí v transformátoru je sekundární výkon o něco málo menší, než primární příkon. [6]

$$\eta = \frac{P_2}{P_1} = \frac{P_2}{P_2 + \Delta P} = \frac{S_2 \cos \varphi}{S_2 \cos \varphi + \Delta P} \quad (3.11)$$

Kde:

$\eta$  – účinnost transformátoru

$P_1$  – primární příkon transformátoru

$P_2$  – sekundární výkon transformátoru

$\Delta P$  – ztráty v transformátoru

$S_2$  – zdánlivý výkon transformátoru

$\cos \varphi$  – účinník

Při průchodu jmenovitým proudem transformátorem jsou ztráty nakrátko označovány jako jmenovité ztráty nakrátko  $\Delta P_{KN}$ .

$$\Delta P_K = \Delta P_{KN} = 3(R_1 + R_2)I_{1N}^2 \quad (3.12)$$

Zvolíme-li si libovolný proud, jsou ztráty nakrátko:

$$\Delta P_K = 3(R_1 + R_2)I_1^2 = 3(R_1 + R_2)(\lambda I_{1N})^2 = \lambda^2 \Delta P_{KN} \quad (3.13)$$

Kde  $\lambda$  je poměrné zatížení a je to tedy poměr libovolného zatěžovacího proudu ku proudu nominálnímu.

$$\lambda = \frac{I_1}{I_{1N}} \quad (3.14)$$

Po zavedení poměrného zatížení lze upravit vztah účinnosti.

$$\eta = \frac{\lambda S_N \cos \varphi}{\lambda S_N \cos \varphi + \Delta P_0 + \lambda^2 \Delta P_{KN}} \quad (3.15)$$

Transformátory mají většinou účinnost více než 0,99 (tedy 99 %). Obecně platí, že transformátory větších výkonů a rozměrů mají větší účinnost, než transformátory menších výkonů a rozměrů. [6]

### 3.1.4 Konstrukční uspořádání

Každý transformátor je tvořen dvěma hlavními částmi a to magnetickým obvodem a vinutím. Další velmi důležitou částí je transformátorová nádoba, jedná-li se o olejový transformátor.

#### 3.1.4.1 Magnetický obvod

Magnetický obvod je tvořen poskládáním speciálních plechů pro elektrotechniku. Plechy jsou velmi tenké, o tloušťce 0,28 mm, 0,35 mm nebo 0,5 mm. Pro omezení ztrát vířivými proudy jsou plechy od sebe izolovány lakem nebo fosfátovou povrchovou úpravou. Ke snížení ztrát vířivými proudy je též přispíváno legováním materiálu plechů křemíkem, který snižuje jeho vodivost. Další možností je použití plechů válcovaných za studena, neboli orientovaných plechů, které mají daný směr magnetizace a menší hysterézní ztráty. Plechy tvořící jádro drží pospolu díky magnetickým spojkám. [8]

Existují dvě konstrukce magnetických obvodů. Jádrová konstrukce a plášťová konstrukce. Jádrová konstrukce znamená, že vinutí jsou rovnoměrně navinuty na všech jádrech, jak vnitřních, tak i postranních. Plášťová konstrukce má vinutí jen na vnitřních jádrech, postranní slouží pouze pro uzavření magnetického toku. [8]

#### 3.1.4.2 Vinutí

Na jádře transformátoru je navinuto vinutí. Každá fáze může mít dvě a více vinutí. Tyto vinutí jsou magneticky vázána prostřednictvím feromagnetického jádra. Vinutí je nejdůležitější částí transformátoru. Jeho poškození mnohdy znamená výměnu celého transformátoru, protože převinutí by byla dražší záležitost. Z tohoto důvodu musí vinutí obstát tepelně (odolat oteplení při průchodu jmenovitým proudem) a mechanicky (odolat silám působícím při zkratech). [8]

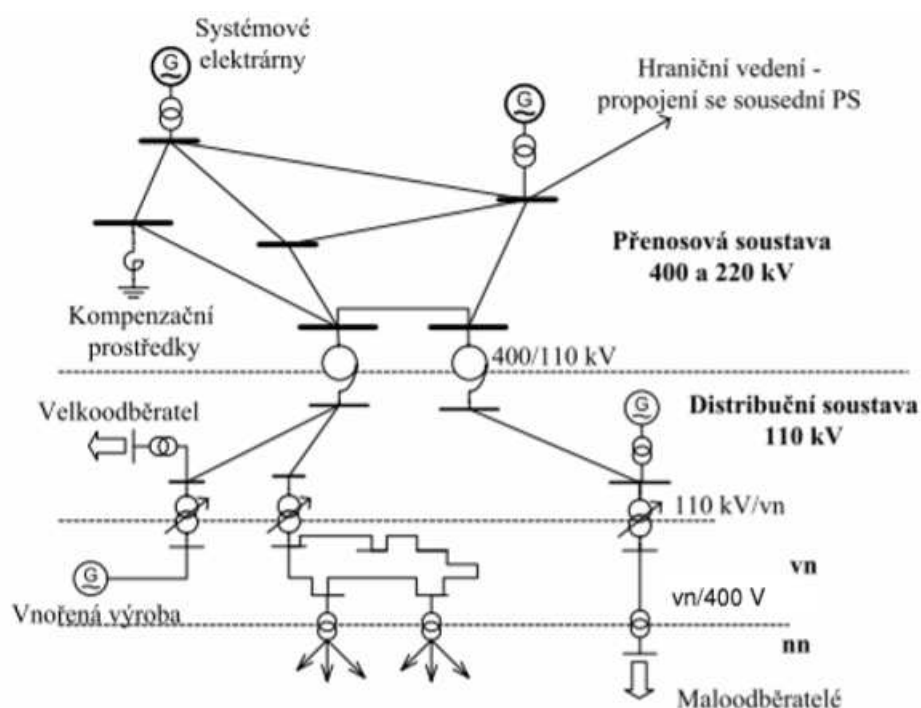
Z konstrukčního řešení je vinutí vytvořeno jako válcové (koncentrické, cylindrické, soustředné) nebo deskové (kotoučové, prostřídané). Válcové vinutí tvoří válec po celé výšce jádra a primární a sekundární vinutí jsou na sobě. U deskového vinutí se primární a sekundární cívky střídají. [8]

#### 3.1.4.3 Nádoba

Z důvodu chlazení transformátoru mohou být transformátory vyšších výkonů ponořeny do nádoby s olejem. Nádoby nemusejí být pouze hladké, pro lepší odvod tepla mohou být nádoby žebrované, ofukované, nebo s přídavným radiátorem. Transformátory největších výkonů mají navíc zvláštní nádobu, kde se olej chladí. Proudění oleje probíhá nuceným oběhem. Transformátory bez nuceného oběhu oleje mají navíc konzervátor, který slouží pro vyrovnání objemové změny oleje s teplotou. Konzervátor s nádobou transformátoru je spojen trubicí ve které je umístěno Buchholzovo plynové relé. Relé slouží jako ochrana, která umí signalizovat vznik plynů v oleji, které vznikají při poruše transformátoru. [8]

## 3.2 Elektrizační soustava

Elektrizační soustava se sestává ze tří základních prvků. Prvky pro: výrobu elektrické energie, přenos, transformaci, distribuci elektrické energie a spotřebu elektrické energie. Dále ji tvoří systémy měřicí, ochranné, řídicí, zabezpečovací, informační a telekomunikační techniky. Od elektrizační soustavy je vyžadováno, aby v požadovaném čase, množství a místě dodávala ke spotřebitelům elektrickou energii, přičemž musí dodržet určitou spolehlivost, kvalitu, hospodárnost a ekologický ohled ze strany výroby, rozvodu i spotřeby. [10] [9] [11]



**Obrázek 3.2:** Zjednodušené schéma elektrizační soustavy [Převzato z [11]]

Základní strom elektrizační soustavy tvoří přenosová soustava. Na přenosovou soustavu navazuje distribuční soustava. Velikost přenosového a distribučního napětí udává technicko-ekonomická rozvaha, přičemž rozhodující je vzdálenost a velikost přenášeného výkonu. V době, kdy se všechny země elektrizovaly, se velikost napětí stanovovala jen podle technicko-ekonomického výpočtu a této velikosti náležely i příslušné zařízení. Tímto způsobem vznikla v řadě zemí rozdílná řada jmenovitých napětí. V poslední době, kdy je hromadná výroba potřebných zařízení a stoupající mezinárodní spolupráce, je vyžadovaná jednotná řada jmenovitých napětí. Normalizované řady České republiky a okolních států se stále liší. Elektrická zařízení jsou vyráběna s určitou tolerancí, proto je možné stejné zařízení používat v různých státech. [10] [9]

Jelikož se elektrická energie nedá skladovat ve velkém množství, je velmi podstatné řízení soustavy. Za řízení je odpovědný dispečink, který určuje v závislosti na velikosti spotřeby a přenosovými schopnostmi elektrického vedení velikost vyráběného výkonu.

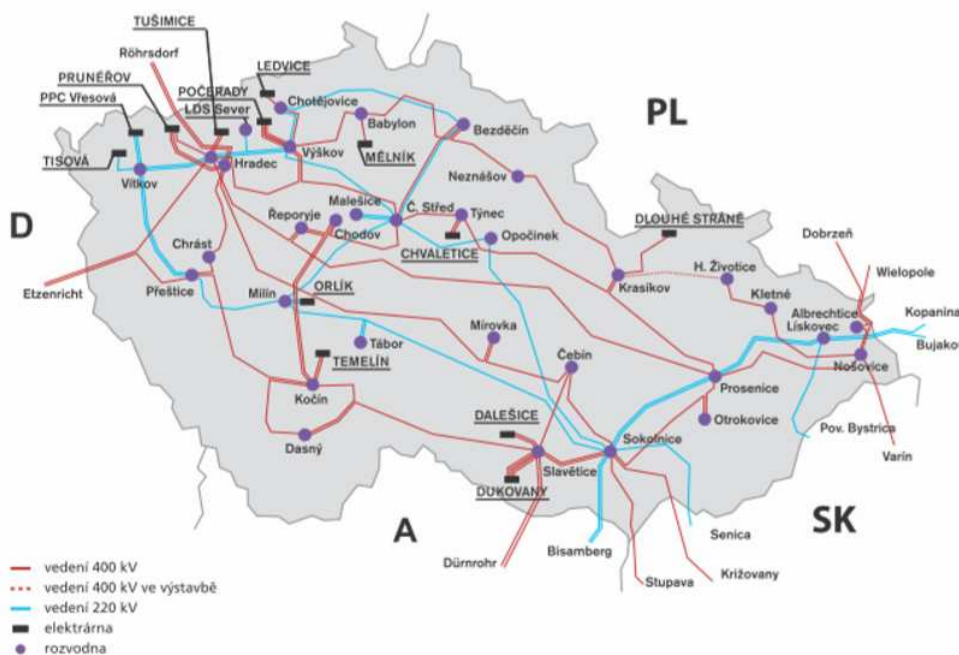
Úkolem dispečinku je zároveň odpovědnost za síť, co se týče odstraňování poruchových stavů a opětovného obnovení dodávky. [10]

|                                     |                  |              |     |                             |      |      |
|-------------------------------------|------------------|--------------|-----|-----------------------------|------|------|
| Nízké napětí<br>(nn) [kV]           | Jmenovité        | 0,4 / 0,23   |     |                             | 0,50 | 0,69 |
|                                     | max. provozovací | 0,42 / 0,241 |     |                             | ---  | 0,73 |
| Vysoké napětí<br>(vn) [kV]          | jmenovité        | 3            | 6   | 10                          | 22   | 35   |
|                                     | max. provozovací | 3,6          | 7,2 | 12                          | 25   | 37   |
| Velmi vysoké napětí<br>(vvn) [kV]   | jmenovité        | 110          |     | 220                         | ---  |      |
|                                     | max. provozovací | 123          |     | 245                         | ---  |      |
| Zvláště vysoké napětí<br>(zvn) [kV] | jmenovité        | 400          |     | 750                         |      |      |
|                                     | max. provozovací | 420          |     | 787 (předp. zvýšení na 800) |      |      |

Obrázek 3.3: Normalizovaná řada střídavých napětí [Převzato z [9]]

### 3.2.1 Přenosová soustava

Přenosová soustava je tvořena zasmyčkovanou okružní sítí o napětích 400 a 220 kV. Jejím úkolem je propojení uzlů, do kterých jsou vyvedeny výkony z velkých systémových elektráren. Též zajišťuje propojení se soustavami sousedních států pomocí hraničních vedení.



Obrázek 3.4: Schéma přenosové soustavy ČR [Převzato z [11]]

Přenosová soustava reguluje frekvenci a vyráběný výkon, který je do soustavy vyveden a udržuje tak rovnováhu v celém území. Musí zajistit stabilitu přenosu i při mimořádných stavech a zajistit spolehlivost přenosu. Uzel transformátoru v přenosové soustavě je provozován jako účinně uzemněný. Provozovatelem přenosové soustavy je společnost ČEPS,

a.s., která dispečersky řídí provoz zařízení přenosové soustavy a systémových zdrojů na území ČR. Zajišťuje tak bezpečný a spolehlivý přenos elektřiny pro uživatele přenosové soustavy ČR i v rámci Evropského trhu s elektřinou. [10] [9] [11]

### 3.2.2 Distribuční soustava

Distribuční soustava je tvořena sítěmi o napětích 110 kV a vn řešených jako okružních nebo paprskových rozvodů. Do distribuční soustavy je přiveden výkon z uzlových stanic 400 (220)/110 kV a výrobních zdrojů malých výkonů, převážně místního charakteru. Například malé vodní elektrárny, průmyslové elektrárny, případně starší vodní a tepelné elektrárny. Tato síť je nazývána *veřejná distribuční soustava*. Síť má charakter venkovského nebo městského rozvodu a jsou z ní napájeny průmyslové závody a elektrická trakce. [10] [11]

Veřejnou distribuční soustavu bychom mohli rozdělit na *elektrické sítě městské* a *elektrické sítě průmyslové*. Městská síť napájí také většinu průmyslových závodů, protože se tyto závody obvykle nachází na území nebo v blízkém okolí měst. Síť vn se rozděluje na síť, která zásobuje velkoodběratele a síť pro zásobování obyvatelstva a služeb. Při konstruování sítí se vychází z počtu *obyvatel/km<sup>2</sup>* a z úrovně elektrifikace domácností. [10] [11]

Průmyslové elektrické sítě se z hlediska charakteru odebíraného výkonu značně liší. Pro návrh sítě se stanovuje tzv. výpočtové zatížení, které představuje maximální současný odběr se zahrnutím ztrát v rozvodu i případného rozšíření závodu. V průmyslových závodech je problém se spínáním spotřebičů velkých výkonů, který vede k rušení kvality napětí. Proto zde musí být opatřena náležitá opatření proti kolísání napětí, nesymetrii napětí, vyšším a mezilehlým harmonickým apod. Důležité je též navrhnout kompenzaci účinniku uvnitř průmyslového závodu, aby nevznikaly zbytečné ztráty na vedení. Snažíme se, aby výsledný účinník byl mezi 0,95 – 1 induktivního charakteru. [10] [11]



**Obrázek 3.5:** Území působnosti distribučních společností ČR [Převzato z [11]]

O konečnou distribuci k zákazníkům se stará téměř 300 distributorů s licenci. Avšak pouze 3 z nich mají největší význam. Jsou jimi:

- **ČEZ** Distribuce, a.s.
- **E. ON** Distribuce, a.s.
- **PRE** Distribuce, a.s.

Tito distributoři se starají hlavně o zákazníky v podobě obyvatelstva. Další nespočet distributorů má pouze lokální charakter (např. velké průmyslové podniky). [11]

### 3.3 Transformátor v distribuční síti

Jedním z nejdůležitějších prvků hlavního silového obvodu všech distribučních transformoven je transformátor. Každé místo do kterého je přiváděna elektrická energie, má jiné požadavky na dodávaný výkon, jak už z hlediska velikosti výkonu, nebo důležitosti dodávky. Z těchto důvodů jsou na transformátor vyvíjeny různé požadavky:

- výpočtové zatížení
- stupeň důležitosti dodávky
- ztráty v transformátoru
- investiční náklady
- přijatelné proudy při zkratu za transformátorem
- odchylky napětí za transformátory v mezích
- možnost paralelního chodu

Pro potřeby zákazníků udává výrobce pro transformátor jmenovitý výkon ( $S_N$ ), jmenovitý převod ( $\frac{U_{1N}}{U_{2N}}$ ), údaje o odbočkách regulace napětí, napětí nakrátko ( $u_k$ ), proud naprázdno ( $i_0$ ), činné ztráty nakrátko ( $\Delta P_K$ ), činné ztráty naprázdno ( $\Delta P_0$ ), zapojení vinutí a příslušný hodinový úhel. V distribuční síti jsou z hlediska napěťové úrovně používány dva hlavní druhy transformátorů. Transformátor 110/22 kV a 22/0,4 kV. Nejčastěji používané výkony transformátorů v distribuční soustavě jsou:

- 110/23 kV : 10; 16; 25; 40 [MVA]
- 110/6,3 kV : 31,5 [MVA]
- vn/0,4 kV : ... 40, 50, 63, 75, 80, 100, 160, 250, 315, 400, 630... [kVA]

### 3.3.1 Spojení vinutí

Vinutí třífázových transformátorů je možné spojovat různými způsoby (hvězda, trojúhelník, lomená hvězda). Primární vinutí může být spojené rozdílně než vinutí sekundární.

Spojení do hvězdy se provede tak, že konce vinutí se spojí do jednoho uzlu. Vznikne nulový bod. Začátky vinutí se připojí na svorky. Je-li nulový bod vyveden, je možné použít jak sdružené, tak i fázové napětí. Toto spojení nese označení Y (vinutí s vyšším napětím), nebo y (vinutí s nižším napětím).

Při spojení do trojúhelníka (D,d), spojíme konec jedné fáze se začátkem druhé fáze. Uzly spojují se vyvedou ke svorkám.

Při spojení do lomené hvězdy (Z,z) je vinutí každé fáze rozděleno na dvě stejné části a navinuto na různé sloupky. Začátky horních polovin vinutí jednotlivých fází se vyvedou ke svorkám, zatímco začátky spodních vinutí se spojí do uzlu. Konce obou částí vinutí se spojí tak, že vinutí  $a_1$  se spojí s koncem vinutí  $b_2$ ,  $b_1$  s  $c_2$  a  $c_1$  s  $a_2$ . Pro spojení vinutí do lomené hvězdy pro totéž napětí, je zapotřebí o 15 % více závitů, než pro vinutí spojené do hvězdy.

Spojení Yy je spojení, při kterém je vstupní i výstupní vinutí spojeno do hvězdy. Toto spojení je výrobně levnější, ovšem nehodí se do míst, kde jsou fáze nesouměrně zatěžovány (nestejně zatížení na jednotlivých fázích). Používá se při transformaci vvn/vvn, vvn/vn a vyjímečně vn/nn.

Spojení, kdy je vinutí vyššího napětí spojeno do trojúhelníku a nižší do hvězdy (Dy) se používá převážně na transformaci vn/nn. Toto spojení je dražší, jelikož na spojení D je zapotřebí o 73 % více závitů a to lépe izolovaných než vinutí Y (při stejném napětí). Snáší dobře nestejně zatížení jednotlivých fází.

Spojení Yz je vhodné pro sítě, kde je nesouměrné zatížení jednotlivých fází, avšak při nesouměrném zatížení má rozdílné napětí jednotlivých fází. Je dražší než spojení Yy a jsou v něm cca o 10 - 15 % větší ztráty v mědi.

Transformátory vvn/vvn a vvn/vn mají v označení spojení ještě třetí písmeno. To značí zapojení vinutí pro kompenzaci nesymetrického zatížení. Toto vinutí je dosti často nevyužito, nebo je přes něj napájena vlastní spotřeba elektrické stanice či kompenzátor. [9]

- 110/vn – ZNy, ZNd
- 22kV/vn – Yy
- 22kV/nn do 160 kVA – Yzn1
- 22kV/nn od 250 kVA – Dyn1

### 3.3.2 Převody

Převod transformátoru je dán poměrem závitů vyšší napěťové strany (vstupní) ku nižší napěťové straně (výstupní). V energetice je převod definován napěťovým poměrem. V praxi se definují 3 druhy převodů:

- jmenovitý převod
- fiktivní převod
- skutečný převod

Jmenovitý převod je dán poměrem jmenovitých napětí traťového napětí, např. 110/23 kV.

$$P = \frac{U_1}{U_2} \quad (3.16)$$

Jmenovité sekundární napětí  $U_2$  je u snižovacích transformátorů o 5 % vyšší než jmenovité napětí sítě  $U_{N2}$ . Napětí je zvýšeno kvůli udržení napětí v dovozených mezích v celé síti, které by bylo jinak nižší z důvodu úbytku na transformátoru vlivem ztrát.

Fiktivní převod je poměrem jmenovitých napětí sítí, např. 110/22 kV.

$$P = \frac{U_{N1}}{U_{N2}} \quad (3.17)$$

Skutečný převod je poměrem počtu skutečně navinutých závitů na primárním vinutí ku počtu navinutých závitů na sekundárním vinutí. [11]

$$P = \frac{N_{11}}{N_2} \quad (3.18)$$

### 3.3.3 Regulace napětí - odbočky

Vlivem průchodu proudu je na transformátoru pokles napětí. Čím bude odebíraný proud větší, tím bude větší úbytek napětí. Pro regulaci výstupního napětí transformátoru slouží odbočky. Transformátory v přenosové síti (vvn/vvn) i distribuční transformátory vvn/vn jsou realizovány jako regulační při zatížení. Odbočky jsou realizovány na straně vyššího napětí a to nejčastěji  $\pm 8 \times 2$  % se středem v odpovídajícím jmenovitému převodu. Odbočky jsou číslovány od nejmenšího počtu závitů k nejvyššímu, přičemž odbočka č. 9 odpovídá jmenovitému převodu. Čili budeme-li chtít zvýšit napětí na výstupní straně, zvolíme na vstupním vinutí nižší číslo odbočky a naopak. [11]


Distribuční transformátory vn/nn jsou realizovány jako regulovatelné bez zatížení. Odbočky jsou provedeny na vstupní straně  $\pm 5$  % od střední, případně i  $\pm 7$  %. Pro přepojení odboček, musí být transformátor v beznapěťovém stavu. Regulace je využívána k potlačení úbytků napětí na dlouhých vedeních a ke srovnání napěťových poměrů za transformátory různě vzdálenými od společného uzlu sítě (rozvaděče, rozvodny). [11]



### 3.3.4 Zatížitelnost

Za předpokladu maximální denní teploty 35 °C a průměrné roční teploty 15 °C je od transformátoru vyžadováno vydržet provoz pod jmenovitým zatížením až 25 let. Při dodržení těchto podmínek, může dosáhnout průměrná teplota nejteplejšího místa vinutí 95 °C. Teplota oleje v horní vrstvě nesmí přesáhnout cca 95 °C. Hlavní faktory na kterých je oteplení závislé jsou velikost zatížení a okolní teplota. Pokud by transformátor byl provozován pod neúplným zatížením, můžeme přes něj po omezenou dobu přenášet vyšší výkon než jmenovitý. Jestliže teplota okolí je trvale nižší než 25 °C, můžeme přes transformátor přenášený výkon zvýšit cca o 1 % na každý stupeň (max. o 15 %). [10]

$$\text{denní využití} = \frac{\text{skutečně odebraná el. energie (za 24 hod.)}}{\text{jmenovitý výkon transformátoru} \times 24} \quad (3.19)$$



**Obrázek 3.6:** Graf zatížitelnosti transformátoru |Převzato z [10]|

Na obr. 3.6 je znázorněn diagram, který udává nejvyšší dovolený proud  $I_m$  v % v závislosti na době přetížení  $t$  při určitém denním využití (0,4 – 0,9).

### 3.3.5 Hospodárné zatěžování

O ekonomickém provozu transformátoru rozhodují jeho ztráty. Jak bylo popsáno v kapitole 3.1.2, jsou ztráty závislé na konstrukci a materiálu jádra (ztráty naprázdno) a ztráty způsobené průchodem proudu (Joulovy ztráty) ve vinutí. Provozem transformátoru nejsme schopni ztráty naprázdno ovlivnit. To čím jde ovlivnit ekonomický provoz a tedy zlepšit či zhoršit účinnost, je odebírané zatížení. Vycházíme z teoretické úvahy, že účinnost je maximální, když nastane rovnost ztrát. [6]

$$\Delta P_0 = \Delta P_K \quad (3.20)$$

Po dosazení do této úvahy jsme schopni odvodit poměrné zatížení  $\lambda$  pro maximální účinnost.

$$\Delta P_0 = \Delta P_K = 3R_K I_{1N}^2 \frac{I_1^2}{I_{1N}^2} = \Delta P_{KN} \lambda_{\eta_{max}}^2 \quad (3.21)$$

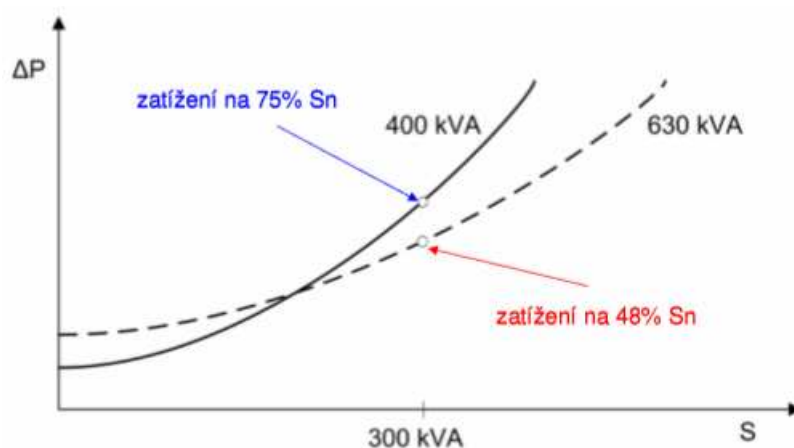
$$\Delta P_0 = \Delta P_{KN} \lambda_{\eta_{max}}^2 \quad (3.22)$$

Úpravou rovnice dostaneme:

$$\lambda_{\eta_{max}} = \sqrt{\frac{\Delta P_0}{\Delta P_{KN}}} \quad (3.23)$$

Dosazením poměrného zatížení pro maximální účinnost do vzorce 3.15 dostaneme vztah pro maximální účinnost [6]:

$$\eta_{max} = \frac{\lambda_{\eta_{max}} S_N \cos \varphi}{\lambda_{\eta_{max}} S_N \cos \varphi + \Delta P_0 + \lambda_{\eta_{max}}^2 \Delta P_{KN}} \quad (3.24)$$



**Obrázek 3.7:** Graf ztrát transformátoru v závislosti na zatížení [Převzato z [11]]

Na obr. 3.7 jsou znázorněny průběhy ztrát v závislosti na velikosti zatížení transformátoru při určitém jmenovitém výkonu. Je tedy možné vidět, že transformátor s vyšším jmenovitým výkonem má menší celkové ztráty, než transformátor s nižším jmenovitým výkonem při stejném zatěžování.

Tento pohled na hospodárnost zatěžování byl pouze z pohledu ztrát v transformátoru. V úvahu musíme brát též ekonomický pohled. To znamená, že nemůžeme do určité sítě vložit transformátor extrémního výkonu oproti reálnému odebíranému výkonu, který stojí velmi velkou částku, jen za vidinou toho, že transformátor bude mít velmi malé ztráty.

# Kapitola 4

## Aplikace neuronové sítě na reálná data z provozu transformátoru

### 4.1 Výhody predikce elektrického zatížení

Pro provedení určitého rozhodnutí je znalost vývoje budoucí události velmi důležitá. Dnes je na predikci založeno velmi mnoho situací. Ať už od ekonomické predikce pro realitní makléře či investory, přes meteorologickou predikci pro předpověď počasí, možného klimatického vývoje na Zemi a výskyty zemětřesení, až po predikci výsledku sportovních utkání. [13]

Pro provozovatele přenosových a distribučních soustav je velmi důležitá predikce elektrického zatížení. Díky predikci jsme schopni odhalit místa, ve kterých by potenciálně mohlo hrozit přetížení a tím způsobená porucha. [13]

V důsledku zatím velmi malé možnosti akumulace elektrické energie, je v elektroenergetice velmi důležitá rovnováha mezi tím, kolik se elektrické energie vyrobí a kolik spotřebuje. Proto význam predikce vyrobené i spotřebované elektrické energie stále roste. Pomocí získaných výsledků jsme schopni činit strategické rozhodnutí a přizpůsobovat správný chod sítě. [13]

Predikce je taktéž velmi využívána pro predikování výroby elektrické energie obnovitelnými zdroji energie (OZE). V dnešní době jsou OZE nejlepším způsobem výroby elektřiny pro omezení spotřeby fosilních paliv. Jejich výroba elektrické energie a zapojení do elektrické soustavy je úzce spjata s předpovědí počasí. Kvůli náhlému nárůstu instalovaného výkonu OZE vznikl nový vědní obor týkající se predikce - energetická meteorologie. [13]

Již poslední dvě dekády se pracuje s různými technikami pro předpověď zatížení energetických systémů. Předpověď zatížení od řádu minut až po jednotky dnů pomáhá operátorům efektivně plánovat diagram denního zatížení, míru zapojení pološpičkových a špičkových elektráren do sítě atd. Značnou důležitost má predikce rovněž pro zabezpečení systému z hlediska předvídání poruch způsobených přetížením. [13] [14]

## 4.2 Druhy přístupů k predikci

### 4.2.1 Časové cykly

Přístup na základě časových cyklů, je založen na principu opakujících se jednotlivých úseků. Odebírané zatížení je jakýsi vzor, který se při stálých podmínkách opakuje stále dokola. Liší se, je-li zatížení v létě či zimě, v pracovní den či o víkendu, nebo ve dne či v noci. Takto vytvořenou predikci lze považovat za stochastický proces, protože je stanovena pouze na základě stejného okamžiku např. v minulém měsíci, či roce. [14]

### 4.2.2 Časové cykly + teplota

V tomto přístupu k predikci je k časovým cyklům přidána i teplota. Je důležité najít správný funkční vztah mezi změnou teploty a změnou zatížení. Pokud by jsme použili i dalších vlivů, jako je vlhkost, rychlost větru a oblačnost, je možné dosáhnout lepších výsledku. V této práci se zabývám pouze použitím teploty.

## 4.3 Vytvoření vstupních hodnot

V kapitole 2 bylo zmíněno, že neuronová síť potřebuje vstupní hodnoty, které by vstupovaly do sítě a na základě nastavených vah sítě, by se tyto hodnoty transformovaly na příslušné výstupní hodnoty. Váhy si síť nastavuje natrénováním. Pro správnou funkci sítě, jsou správně nadeklarované vstupní hodnoty zásadní věc. Vstupní hodnoty představují vlivy, podle kterých se mění výstupní hodnoty. V našem případě představují vstupní hodnoty matice, v jejíž jednotlivých řádcích jsou zakódované roční období, měsíce v roce, dny, hodiny, minuty a teplota. Ve složitějších případech by bylo možné, zahrnout do vstupní matice i vlhkost či rychlost větru. Pro jednotlivé predikce jsou vstupní hodnoty rozdílné. Některé predikce jsou jen v závislosti na čase, jiné zase i včetně teploty.

Nejprve jsem vytvořil obecnou vstupní matici, ze které jsem poté pro jednotlivé druhy predikcí vybíral potřebné hodnoty. Byly mi poskytnuty naměřené výkony z transformátorů, které byly zaznamenávány s krokem 1 minuty. Proto jsem vytvořil i vstupní matici, ve které byl zakódovaný nejprve pouze čas s krokem 1 minuty. Jako první jsem vytvořil matice jednotlivých dnů v týdnu (Po, Út, St, Čt, Pá, So, Ne). Vytvořený den měl v 1.–7. řádce logickou hodnotou 1 či 0 označené o jaký den v týdnu se jedná, v 8. řádce byla zakódována hodina (0 – 23 hod., přepočítaná do intervalu <0;1>) a v 9. řádce byla zakódována minuta (0 – 59 min., přepočítaná do intervalu <0;1>).

```
>> ut(:,100)
```

```
ans =
```

```
0      %% Po
```

```

1.0000    %% Út
          0    %% St
          0    %% Čt
          0    %% Pá
          0    %% So
          0    %% Ne
0.0417    %% hodina/24
0.6500    %% minuta/60

```

Takto vypadá vypsaný 100. řádek z matice dnu úterý. Jedná se tedy o úterý, 01 : 39 hod. Matice jednotlivých dnů obsahovala tedy 9 řádků a 1440 sloupců (počet minut za den).

Po vytvoření jednotlivých dnů v týdnu jsem vytvořil celý den sloučením matic jednotlivých dnů.

```
>> tyden=[po ut st ct pa se ne];
```

Vytvořením matice **tyden** už mohu snadno vytvořit celý požadovaný měsíc. Pro ukázkou, např. měsíc květen z roku 2014 (rok 2014 proto, že dostupné naměřené výkony z transformátoru jsou z roku 2014). Měsíc květen začíná dnem čtvrtek, začnu tedy dnem čtvrtek a sloučím ho s následujícími dny a určitým počtem týdnů tak, jak se přesně v tomto měsíci vyskytují. K zakódování, že se jedná o měsíc květen a tím pádem i jaro, použiji obdobný způsob zakódování, jako u zakódování dne v týdnu. Vyžiji k tomu 1.– 5. řádek, kdy v 1.– 4. řádku zakóduji pomocí logické hodnoty 1 o jaké roční období se jedná a v 5. řádku zakóduji příslušný měsíc (číslem 1 – 12, přepočítáno do intervalu <0;1>).

```

>> kveten=[ct pa so ne tyden tyden tyden po ut st ct pa so]; %% sestavení měsíce
>> kveten(6:14,:)=kveten; %% uvolnění 1.- 5. řádku
>> kveten(1,:)=1 %% označené roční období
>> kveten(2:4,:)=0; %% označené roční období
>> kveten(5,:)=5/12; %% zakódovaný měsíc

```

Tímto způsobem jsem vytvořil všech 12 měsíců. Matice jednotlivých měsíců obsahovala 14 řádků a buď 40 320, 43 200 nebo 44 640 sloupců (minut za měsíc) dle toho, kolik dnů měl jednotlivý měsíc (28, 30, 31). Obdobným složením matic 12ti měsíců bylo možné vytvořit matici pro celý rok 2014. Matice celého roku obsahovala 14 řádků a 525 600 sloupců (minut za rok).

```
>> rok=[leden unor brezen duben kveten červen červenec srpen zari rijen listopad
        prosinec];
```

Od firmy Meteoblue AG ([www.meteoblue.com](http://www.meteoblue.com)) mi byly poskytnuty meteorologické údaje pro město Plzeň z roku 2014. Bohužel se nejedná o přesně naměřené hodnoty, ale jen o predikci, která by měla být velmi přesná. Z poskytnutých hodnot jsem využil pouze teplotu. Dostupné údaje o teplotě jsou v hodinových intervalech, proto v predikcích, u kterých je použita ve vstupní matici teplota, jsou predikce pouze v hodinových intervalech.

V predikcích je též využíváno, jako vstupní hodnoty, maximální, minimální a průměrná denní teplota. Z poskytnutých dat o teplotě bylo tedy zapotřebí vybrat tyto hodnoty.

Jelikož jednotlivé predikce se budou vztahovat k určitým měsícům, či dnům v roce, bylo zapotřebí vytvořit lehký skript, který by generoval vstupní matici podle toho, o jaký časový interval se jedná a jaké časové údaje a teploty by měl obsahovat.

Nyní máme vytvořené potřebné matice představující vstupní hodnoty, na kterých závisí zatížení transformátoru.

## 4.4 Cílové hodnoty

Za cílové hodnoty jsou považovány reálné naměřené hodnoty výkonů z distribučních transformátorů v Plzni. Jedná se o transformátory 110/22 kV. Město Plzeň je napájeno elektrickou energií z nadřazené přenosové soustavy skrze transformátory Chrást (400/110 kV) a Přeštice (400/220/110 kV). Tyto transformátory a rozvodny jsou majetkem společnosti ČEPS a.s. Na tyto transformátory v přenosové soustavě navazují transformátory v distribuční soustavě, které jsou v majetku společnosti ČEZ Distribuce a.s. Hlavními transformátory, které napájí město elektrickou energií jsou transformátory 110/22 kV Plzeň město, Plzeň Sever a Křimice, napájené z rozvodny Chrást (110 kV). Dalšími důležitými transformátory jsou Plzeň Jih a Černice, které napájí rozvodna Přeštice (110 kV). Rozvodny Chrást a Přeštice jsou z důvodu zálohovatelnosti propojeny na úrovni 110 kV.

V mé práci jsou k predikci využity naměřené výkony z transformátorů Plzeň Sever a Černice. V Černicích se jedná o dva šedesátitunové transformátory o výkonu 40 MVA od Plzeňské fimry ETD, přičemž je v provozu vždy jen jeden a druhý slouží jako záložní. [12]

Cílové hodnoty jsou hodnoty, které se snaží síť přiřadit k příslušným vstupům a tím nastavit váhy neuronu. Z laického pohledu by se dalo říci, že neuronová síť se naučí příslušné naměřené výkony na základě toho, v jaký čas nebo při jakém počasí byly naměřeny.

V predikcích je též využíváno vstupních hodnot, jako je špičkové denní zatížení a celkové denní zatížení. Jejich výpočet je popsán v kapitole u jednotlivých predikcí.

## 4.5 Architektura použité sítě

V kapitole 2 jsme definovali neuronovou síť jako hustě propojené pole prvků zvaných neurony. Architektura sítě je typu vícevrstvá dopředná síť, skládající se ze tří vrstev. Vrstva vstupní je tvořena určitým počtem neuronů podle toho, kolik řádků obsahuje vstupní matice. Druhá vrstva, nebo-li skrytá vrstva, se skládá z počtu neuronů námi zvolenými pro nejlepší produkci výsledků. Obecně platí, že čím více je vstupních hodnot, tím více je neuronů ve skryté vrstvě (cca  $2 \times$ ). Jako přenosová funkce ve skryté vrstvě je použita bipolární sigmoidální funkce (viz. kapitola 2.3.1). Na skrytou vrstvu navazuje výstupní vrstva tvořena jedním neuronem s lineární přenosovou funkcí (viz. kapitola 2.3.1).

## 4.6 Predikce zatížení

Neuronovou síť je možné využívat na všechny možné způsoby výpočtu. V této práci se zabývám více možnostmi predikce různých typů zatížení:

- denní špičkové zatížení
- celkové denní zatížení
- hodinové zatížení

Při výpočtu predikce se postupuje u všech způsobů stejně. Nejprve se stanoví na jakých vstupních hodnotách nejlépe závisí výstupní hodnota, v našem případě jeden ze druhů zatížení. V druhém kroku se upřesní architektura sítě a počet skrytých neuronů. Natrénování sítě zabere určitý čas (v řádu minut, dle výkonosti PC), ten závisí na složitosti průběhu hodnot a na počtu hodnot. V tomto je síť velmi prospěšná, jelikož nejdelší čas zabere pouze trénink sítě. Simulace a výpočet výstupních hodnot už je velmi rychlý.

K porovnání úspěšně predikovaného zatížení se skutečným zatížením poslouží relativní chyba zatížení (error), která se vypočte jako:

$$error = \frac{|\text{skutečné zatížení} - \text{predikované zatížení}|}{\text{skutečné zatížení}} \times 100 \quad (4.1)$$

### 4.6.1 Denní špičkové zatížení

Denním špičkovým zatížením se rozumí maximální odebíraný výkon  $P$  [MW] v určitý den. Vstupní matice pro výpočet se skládá ze zakódování o jaký den v týdnu se jedná, průměrné denní teploty, maximální denní teploty a nejnižší denní teploty. Výstup ze sítě je maximální denní zatížení. Ve skryté vrstvě je použito 20 neuronů.

**Vstupní vrstva :**  $d, T_a(d), T_{min}(d), T_{max}(d)$

**Skrytá vrstva :** 20 skrytých neuronů

**Výstupní vrstva :**  $P(d)$

kde:

$d$  = den predikovaného špičkového zatížení

$P(d)$  = špičkové zatížení v den  $d$

$T_a(d)$  = průměrná teplota v den  $d$

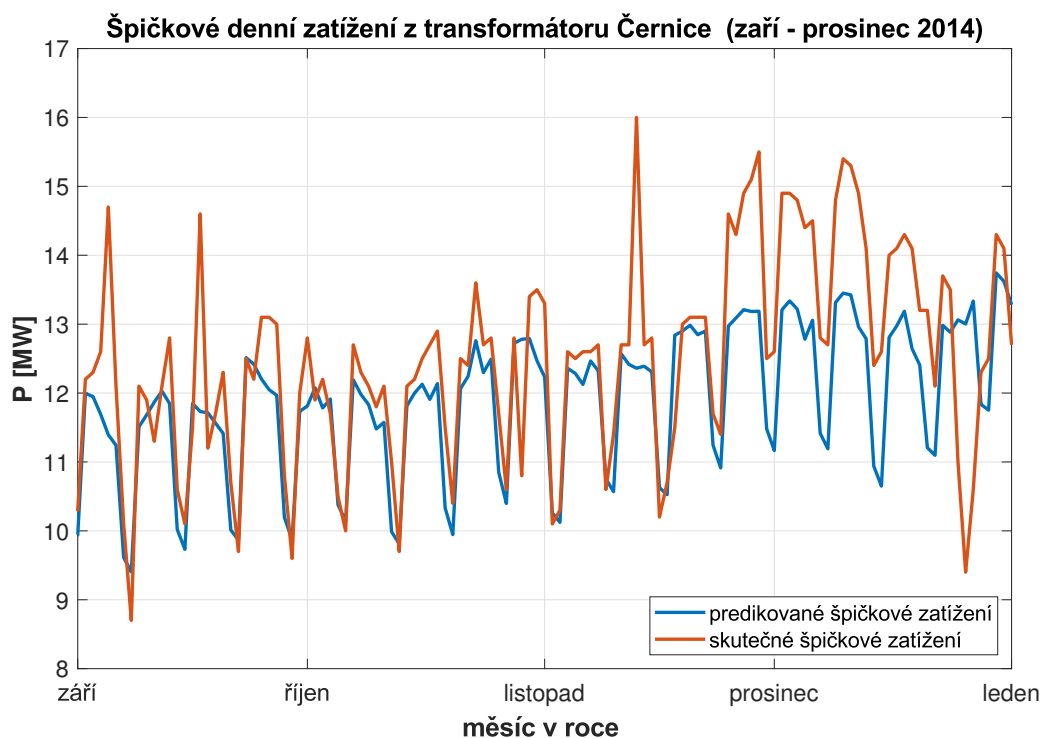
$T_{min}(d)$  = nejnižší teplota v den  $d$

$T_{max}(d)$  = maximální teplota v den  $d$

Platí, že čím více hodnot je použito jako trénovacích dat, tím jsou výsledky sítě přesnější. Proto jako trénovací data byly použity vstupní hodnoty a jím příslušející špičkové zatížení z období měsíců leden až srpen roku 2014.

Aby bylo možné predikci zkontrolovat a určit její chybu od skutečných hodnot, byla uskutečněna predikce pouze pro měsíce září až prosinec, protože data z transformátorů jsou pouze z roku 2014. Naučená síť pro tento úkol predikovala špičkové denní zatížení v rozsahu 4 měsíců dopředu (září až prosinec).


U transformátoru Černice byla data predikována s průměrnou chybou 6,65 %. U transformátoru Plzeň Sever predikovala síť poněkud horší výsledky a to s průměrnou chybou 7,64 %. Zatím se jedná o průměrnou chybu predikce pro všechny 4 měsíce, proto se může jevit takto odchylka jako příliš velká. Průběh špičkového zatížení z transformátoru Černice je na obr. 4.1 a z transformátoru Plzeň Sever na obr. 4.2.




**Obrázek 4.1:** Špičkové denní zatížení z transformátoru Černice (září až prosinec 2014)

Kdybychom uvažovali, že další rok bude stejné špičkové zatížení a teplota, predikce celého roku pro transformátor Černice by byla s průměrnou chybou 6,80 % (obr. 4.3) a pro transformátor Plzeň Sever s průměrnou chybou 8,21 % (obr. 4.4).






Obrázek 4.2: Špičkové denní zatížení z transformátoru Plzeň Sever (září až prosinec 2014)



Obrázek 4.3: Špičkové denní zatížení z transformátoru Černice v roce 2014



Obrázek 4.4: Špičkové denní zatížení z transformátoru Plzeň Sever v roce 2014

#### 4.6.2 Celkové denní zatížení

Celkové denní zatížení je celková spotřebovaná energie za celý den v MWh. Vstupní matice pro predikci tohoto typu zatížení je úplně stejná jako pro predikci špičkového zatížení. Skládá se tedy ze zakódovaného dne v týdnu, průměrné, nejvyšší a nejnižší denní teploty. Ve skryté vrstvě je umístěno 20 neuronů. Výstupní vrstva je tvořena jedním neuronem a jeho výstupní hodnota je požadované celkové denní zatížení.

**Vstupní vrstva :**  $d, T_a(d), T_{min}(d), T_{max}(d)$

**Skrytá vrstva :** 20 skrytých neuronů

**Výstupní vrstva :**  $P(d)$

kde:

$d$  = den predikovaného celkového denního zatížení

$P(d)$  = celkové denní zatížení v den  $d$

$T_a(d)$  = průměrná teplota v den  $d$


$T_{min}(d)$  = nejnižší teplota v den  $d$

$T_{max}(d)$  = maximální teplota v den  $d$

Pro natrénování sítě byla použita data z období leden až srpen roku 2014. Z dostupných hodnot z transformátorů, výkonů které jsou zaznamenány s krokem jedné minuty, jsme celkové denní zatížení dostali pomocí vzorce:

$$\text{celkové denní zatížení v den } d = \sum_{m=1}^{1440} \frac{W(m, d)}{60} \quad [Wh] \quad (4.2)$$


kde  $W(m, d)$  je zatížení v minutě  $m$  ve dni  $d$ .




**Obrázek 4.5:** Celkové denní zatížení z transformátoru Černice (září až prosinec 2014)

Naučená síť predikovala celkové denní zatížení o trochu lepší, než předchozí síť špičkové zatížení. U transformátoru Černice byla predikována data 4 měsíce dopředu s průměrnou chybou 5,81 %. Jeho průběh je možné vidět na obr. 4.5. Celkové denní zatížení pro transformátor Plzeň Sever bylo predikováno s průměrnou chybou 6,30 %.


Pokud bychom chtěli z takto naučené sítě předpovídat opět celý rok, predikce by pro transformátor Černice byla s průměrnou chybou 5,42 % a pro transformátor Plzeň Sever s průměrnou chybou 8,29 %. Průběhy predikovaných zatížení v porovnání se skutečnými celkovými denními zatíženími u obou transformátorů je možné vidět na obr. 4.7 a obr. 4.8



**Obrázek 4.6:** Celkové denní zatížení z transformátoru Plzeň Sever (září až prosinec 2014)



**Obrázek 4.7:** Celkové denní zatížení z transformátoru Černice v roce 2014



Obrázek 4.8: Celkové denní zatížení z transformátoru Plzeň Sever v roce 2014

### 4.6.3 Hodinové zatížení

Hodinovým zatížením se rozumí výkon, který je právě v danou hodinu odebírán. Průběh spotřeby výkonu za den nám ukazuje denní diagram zatížení. Správně natrénovaná neuronová síť je schopna diagram zatížení s jemnou odchylkou předpovědět. Odchylka se liší, jedná-li se o hodinovou, 24 hodinovou, či 48 hodinovou předpověď.

Ve vstupní matici byly pro vstupní neurony použity odlišné hodnoty, než pro výpočet špičkového či celkového denního zatížení. Predikce denního diagramu zatížení je náročnější aplikace, a proto byly jako vstupní hodnoty použity zakódování o jaký den a hodinu se jedná, příslušná teplota v tuto hodinu, odebíraný výkon a příslušná teplota v okamžik před jednonásobkem a dvojnásobkem predikovaného času. Ve skryté vrstvě bylo umístěno 30 neuronů. Výstupní vrstva produkuje hodnoty pro jednotlivé hodinové zatížení. Pro natrénování sítě byly použity opět hodnoty z období leden až srpen roku 2014.

**Vstupní vrstva** :  $d, h, P(h-2m), P(h-m), T(h-2m), T(h-m)$  a  $T(h)$

**Skrytá vrstva** : 30 skrytých neuronů

**Výstupní vrstva** :  $P(h)$

kde:

$h$  = hodina predikovaného zatížení


$m$  = délka předpovědi

$P(x)$  = zatížení  $m$  hodin před hodinou  $h$

$T(x)$  = teplota  $m$  hodin před hodinou  $h$


$T(k)$  = teplota v hodinu  $h$

Síť byla trénována pro čtyři možnosti délky předpovědi. Nejprve pro hodinovou, poté 24 hodinovou, 48 hodinovou a týdenní předpověď. Každá tato možnost si žádala vlastní upravení vstupní matice a natrénování sítě.



**Obrázek 4.9:** Denní diagram zatížení z 10. 11. 2014 z transformátoru Černice

Jednotlivé průběhy všech délek predikce z transformátorů Černice a Plzeň Sever jsou znázorněny na obr. 4.9 a obr. 4.10. S nejlepší přesností a tedy nejmenší relativní chybou vycházela predikce zatížení 1 hodinu dopředu. U transformátoru Černice byla chyba byla v průměru 4,15 % a u transformátoru Plzeň Sever pouhé 2,83 %. Čím delší dobu dopředu je predikce udávána, tím méně je predikce přesná a relativní chyba se zvětšuje.



Obrázek 4.10: Denní diagram zatížení z 10. 11. 2014 z transformátoru Plzeň Sever

# Kapitola 5

## Porovnání výsledků modelů a skutečnosti

V následujících tabulkách je pomocí relativní chyby, nazvané *error*, vypočtené dle rov. 4.1, porovnáno zatížení predikované modely neuronových sítí se zatížením skutečným. Pro predikci všech zatížení proběhl trénink sítě na tréninkových datech z období leden až srpen roku 2014. Pro možnost ověření výsledků byla predikce uskutečněna pro měsíce září až prosinec roku 2014.

Predikce zatížení typu *špičkové denní zatížení* (4.6.1) a *celkové denní zatížení* (4.6.2) ve vzdálenějších měsících od období, ve kterém byla síť trénována, se jeví jako méně přesná, jelikož se jedná o velkou predikci dopředu.

Chyba za celý rok je pouze velmi orientační, jelikož porovnává skutečné a predikované zatížení za celý rok, tedy i za období, podle kterého se síť učila. Nemůžeme ji tedy považovat za skutečnou chybu predikovaného zatížení na celý rok. Berme ji jen v úvahu, jako chybu, kdyby například bylo další rok velmi podobné zatížení a teploty, jako v roce, podle kterého se síť učila.

| Měsíc predikce<br>špičkového denního zatížení | Error pro transf.<br>Černice [%] | Error pro transf.<br>Plzeň Sever [%] |
|---|----------------------------------|--------------------------------------|
| září  | 5,78                             | 5,78                                 |
| říjen   | 4,57                             | 7,65                                 |
| listopad                                      | 5,76                             | 4,80                                 |
| prosinec                                      | 11,31                            | 12,69                                |
| průměr predikovaného období                   | 6,65                             | 7,64                                 |
| celý rok                                      | 6,80                             | 8,21                                 |

**Tabulka 5.1:** Error špičkového denního zatížení

Při predikci *špičkového denního zatížení* (4.6.1) pro transformátor Černice byla dosažena nejmenší chyba 4,57 % . Tato chyba byla při predikci v měsíci říjnu. V průměru všech čtyř predikovaných měsíců byla chyba 6,65 % . Při predikci pro transformátor Plzeň Sever



byla dosažena menší chyba, a to 4,80 % v měsíci listopadu. Ovšem průměrná chyba všech čtyř měsíců byla větší než u předchozího transformátoru, a to 7,64 %.

| Měsíc predikce celkového denního zatížení | Error pro transf. Černice [%] | Error pro transf. Plzeň Sever [%] |
|---|-------------------------------|-----------------------------------|
| září                                      | 3,52                          | 3,70                              |
| říjen                                     | 5,50                          | 4,73                              |
| listopad                                  | 5,90                          | 3,52                              |
| prosinec                                  | 8,48                          | 13,31                             |
| průměr predikovaného období               | 5,81                          | 6,30                              |
| celý rok                                  | 5,42                          | 8,29                              |

**Tabulka 5.2:** Error celkového denního zatížení

Predikce *celkového denního zatížení* (4.6.2) vycházela o pár procent lépe než *predikce špičkové-ho zatížení* (4.6.1). *Celkové denní zatížení* je snáze predikovatelná hodnota. Opakující se vzor tohoto zatížení je oproti špičkovému zatížení stálější a nejsou v něm příliš náhlé výkyvy.

| Měsíc predikce hodinového zatížení | Error 1 hod. predikce [%] | Error 24 hod. predikce [%] | Error 48 hod. predikce [%] | Error týdenní predikce [%] |
|------------------------------------|---------------------------|----------------------------|----------------------------|----------------------------|
| září                               | 4,54                      | 7,19                       | 8,19                       | 8,35                       |
| říjen                              | 4,45                      | 7,90                       | 7,99                       | 9,36                       |
| listopad                           | 3,63                      | 6,64                       | 7,38                       | 8,69                       |
| prosinec                           | 4,02                      | 7,71                       | 10,07                      | 10,27                      |
| průměr pr. období                  | 4,15                      | 7,37                       | 8,41                       | 9,16                       |
| celý rok                           | 4,08                      | 6,47                       | 7,35                       | 7,44                       |

**Tabulka 5.3:** Error hodinového zatížení pro transformátor Černice

Nejnižší chyba byla u transformátoru Černice dosažena v měsíci září, a to 3,52 %. Průměrná chyba za celé predikované období činila 5,81 %. U transformátoru Plzeň Sever byla nejnižší chyba v měsících listopad a září, a to 3,52 % a 3,70 %. Průměrná chyba za celé predikované období činila 6,30 %.


Při predikci *hodinového zatížení* (4.6.3) se chyba u jednotlivých predikovaných měsíců tolik neliší, liší se ovšem chyba jednotlivých délek predikce. U transformátoru Černice je chyba v průměru všech čtyř měsíců u hodinové predikce 4,15 %, u 24 hodinové predikce 7,37 %, u 48 hodinové predikce 8,41 % a u týdenní predikce 9,16 %.

Predikce *hodinového zatížení* (4.6.3) pro transformátor Plzeň Sever byla poněkud přesnější. Průměrná chyba u hodinové predikce byla 2,83 %, u 24 hodinové predikce 5,72 %, u 48 hodinové predikce 7,11 % a u týdenní predikce 9,46 %.

| Měsíc predikce<br>hodinového zatížení | Error 1 hod.<br>predikce [%] | Error 24 hod.<br>predikce [%] | Error 48 hod.<br>predikce [%] | Error týdenní<br>predikce [%] |
|---------------------------------------|------------------------------|-------------------------------|-------------------------------|-------------------------------|
| září                                  | 2,96                         | 5,03                          | 6,17                          | 5,71                          |
| říjen                                 | 2,92                         | 5,31                          | 5,91                          | 8,93                          |
| listopad                              | 2,60                         | 4,64                          | 5,83                          | 7,69                          |
| prosinec                              | 2,85                         | 7,85                          | 10,47                         | 15,35                         |
| průměr pr. období                     | 2,83                         | 5,72                          | 7,11                          | 9,46                          |
| celý rok                              | 2,75                         | 5,00                          | 5,66                          | 6,75                          |

**Tabulka 5.4:** Error hodinového zatížení pro transformátor Plzeň Sever

Co se týče porovnání výsledků se skutečnými hodnotami, mají výsledky, predikované modely, zcela jasně zachovanou "obálku", jako mají skutečné hodnoty. Tato "obálka" je většinou jen posunuta o jinou hodnotu. Takovéto náhlé posunutí "obálky" skutečných hodnot, může být způsobeno například poruchou kterou v našem případě nejsme schopni odhadnout.



**Obrázek 5.1:** Ukázka detailu špičkového denního zatížení z transformátoru Černice

Na obr. 5.1 je možné si povšimnout detailu, že predikované hodnoty neuronové sítě po většinu času kopírují obálku skutečných hodnot. V částech průběhu označených šipkou síť správně reagovala na změnu některých z parametrů, na kterých závisí zatížení.

# Kapitola 6

## Závěr

Cílem této práce bylo vyzkoušet možnost využití neuronové sítě pro predikování zatížení distribučního transformátoru. Nastínil jsem přibližnou architekturu neuronové sítě, pomocí které je možné predikovat zatížení. Síť jsem využil pro 3 různé druhy zatížení. Aby bylo možné síť využít v reálném provozu, bylo by zapotřebí v některých případech dosáhnout ještě větší přesnosti. Odchylka od skutečných hodnot se v průměru u všech druhů predikce pohybovala okolo 6 %, tedy přibližně 94 % úspěšnost. U hodinové predikce zatížení jsme dosáhli dokonce odchylky jen 2 % a tedy přibližně 98 % přesnost.

Neuronová síť je vhodná pro naučení vzoru zatížení závislého na teplotě z tréninkového setu dat. Tento vzor lze lehce měnit podle toho, jak se bude teplota měnit v budoucnosti.

Důvodem, proč nevycházela predikce ještě přesněji, je dle mého názoru a pozorování průběhů to, že tréninkové datové sety, na kterých probíhal trénink sítě, nebyly vhodně upraveny. Data obsahovala i různé náhlé výkyvy, které byly s největší pravděpodobností způsobeny poruchou nebo rekonfigurací distribuční sítě. Tyto provozní stavy, které mohly nastat v jiné části distribuční sítě, než pro kterou bylo zatížení predikováno, se projeví zvýšením zatížení uvažovaného transformátoru. V důsledku poruchy nebo rekonfigurace distribuční sítě byl tok výkonu odkloněn přes transformátor, pro jaký byla zjišťována predikce a tím pádem došlo k odchylce predikovaného zatížení, než při obvyklém provozu. V případě dlouhodobých změn toku výkonu transformátorem se může jednat například o změnu zapojení sítě kvůli údržbě. V tomto případě se zvedla jen střední hodnota výkonu a průběh (nebo-li "obálka", jak se zmiňuji v kapitole 5) zůstal stejný. Tento úkaz můžeme vidět například na obr. 4.4 a 4.7.

Tyto stavy by byly snáze predikovatelné, kdyby data pro trénování sítě obsahovala i záznamy o poruchách v okolních transformátorech, či jiných úsecích distribuční sítě. Neuronová síť by potom predikovala přesněji, protože by věděla, že když nastane v jiné části distribuční soustavy porucha, má predikovaný vzor posunout o určitou střední hodnotu výše.

Dalším velmi důležitým faktorem, který ovlivňuje přesnost predikce zatížení je přesnost předpovědi počasí. Předpovídané zatížení je na těchto datech závislé a odchylka od skutečných hodnot nemusí zajistit správnou predikci zatížení.

V kapitole 4.3 bylo nastíněno vytvoření vstupních hodnot, které obsahovaly více parametrů, než kterých bylo mnou využito. Zapojení parametrů, jako jsou označení měsíce či ročního období, by bylo vhodné, jen pokud bychom trénovali síť na datech z celého roku provozu transformátoru. V mém případě, kdy jsem trénoval neuronovou síť jen na datech z období leden až srpen, bylo zavedení těchto parametrů nevhodné, síť generovala nesmyslné hodnoty v měsících, které jí byly neznámé.

Představený model neuronové sítě implementovaný do programu, který by aktualizoval trénování sítě na aktuálních naměřených výkonech a teplotách, je dle mého názoru velmi vhodný pro využití při plánování provozu elektrizační soustavy nebo při přípravě provozu elektroenergetického zdroje.

Neuronovou síť by bylo možné též využít pro doplnění chybějících či chybných dat z měřících přístrojů, které zaznamenávají průběh výkonu transformátoru. Poruchou či odstavením měřícího přístroje přicházíme o hodnoty, které by mohly být důležité v následných statistických výpočtech. Aplikací neuronové sítě bychom byli schopni prázdná, nebo špatně zaznamenaná místa v celkovém průběhu výkonu doplnit.

# Reference, použitá literatura

- [1] ZURADA, Jacek M. *Introduction to artificial neural systems*. St. Paul: West, c1992. ISBN 0-314-93391-3.
- [2] ROJAS, Raúl. *Neural networks: a systematic introduction*. Berlin: Springer, c1996. ISBN 3-540-60505-3.
- [3] LENK, Peter. *Využití prostředí MATLAB pro neuronové sítě: Usage of the MATLAB environment for neural networks*. Brno, 2009. Bakalářská práce. Vysoké učení technické. Fakulta elektrotechniky a komunikačních technologií, 2009.
- [4] DEMUTH, Howard Demuth, Mark BEALE a Martin HAGAN. *Neural Network Toolbox<sup>TM</sup> User's Guide*. Verze 6.0.3. Natick: The MathWorks, 2008.
- [5] *MATLAB – Wikipedie*. [online]. Wikipedie: [cit. 16.5.2019]. Dostupné z: <https://cs.wikipedia.org/wiki/MATLAB>
- [6] BARTOŠ, Václav. *Teorie elektrických strojů*. Plzeň: Západočeská univerzita, 2006. ISBN 80-7043-509-7
- [7] BARTOŠ, Václav. *Elektrické stroje*. Plzeň: Západočeská univerzita, 2006. ISBN 80-7043-444-9.
- [8] MĚŘIČKA, Jiří, Václav HAMATA a Petr VOŽENÍLEK. *Elektrické stroje*. Praha: Vydavatelství ČVUT, 1993. ISBN 80-01-02109-2.
- [9] MERTLOVÁ, Jiřina a Martin KOČMICH. *Elektrické stanice a vedení*. Vyd. 2., upr. Plzeň: Západočeská univerzita, 1997. ISBN 80-7082-356-9.
- [10] TESAŘOVÁ, Miloslava. *Průmyslová elektroenergetika*. Plzeň: Západočeská univerzita, 2000. ISBN 80-7082-703-3.
- [11] TESAŘOVÁ, Miloslava. *Učební materiály z předmětu EE2*. 2018 [cit. 2019-04-07]. Dostupné z: <https://courseware.zcu.cz/>
- [12] České energetické závody [online]. Copyright © 2019, ČEZ, [cit. 02.05.2019]. Dostupné z: <https://www.cezdistribuce.cz>

- [13] *Predikce v energetice 2: Proč jsou predikce v energetice důležité a proč nemusí vyjít?* [online]. O energetice: [cit. 02.05.2019]. Dostupné z: <https://oenergetice.cz/ostatni/predikce-energetice-2-proc-jsou-predikce-energetice-dulezite-proc-nemusi-vyjit/>
- [14] PARK, D.C., M.A. EL-SHARKAWI, R.J. MARKS, L.E. ATLAS a M.J. DAMBORG. *Electric load forecasting using an artificial neural network*. IEEE Transactions on Power Systems [online]. 6(2), 442-449 [cit. 2019-05-02]. DOI: 10.1109/59.76685. ISSN 08858950. Dostupné z: <http://ieeexplore.ieee.org/document/76685/>