

TECHNICKÁ UNIVERZITA V LIBERCI

FAKULTA TEXTILNÍ



Maroš Tunák

Detekce vad v plošných textiliích

AUTOREFERÁT DISERTAČNÍ PRÁCE

Název disertační práce: **DETEKCE VAD V PLOŠNÝCH TEXTILIÍCH**

Autor: **Maroš Tunák**

Obor doktorského studia: textilní materiálové inženýrství

Forma studia: prezenční

Školící pracoviště: Katedra textilních materiálů

Školitel: Doc. RNDr. Aleš Linka, CSc.

Školitel specialista:

Liberec duben 2008

1. Předmět a cíl práce

Vizuální kontrola textilií je důležitou součástí kontroly kvality v textilním průmyslu. Jejím účelem je dosažení maximální kvality textilních výrobků. Z některých provedených studií vyplynulo, že cena textilních výrobků 2. jakosti je mezi 45 % - 65 % ceny výrobků 1. jakosti. Za účelem udržení vysoké kvality a standardů zavedených v textilním průmyslu musí textilní výrobci sledovat kvalitu svých výrobků, a to i několikanásobně opakovanou kontrolou. Monitorování kvality se dotýká především finální fáze výroby, která vyžaduje objektivní, spolehlivé, časově a finančně efektivní vyhodnocení.

V současné době se vady detekují především subjektivní vizuální kontrolou plošných textilií prováděnou člověkem, což je práce časově náročná a vyžaduje permanentní pozornost kontrolora. Takovéto zjišťování vad, které mají někdy velikost jen pár milimetrů na velmi rozsáhlé inspekční ploše, poskytuje maximální přesnost něco kolem 70 %. Toto je jedním z důvodů, proč má textilní průmysl zájem na nahrazení současných subjektivních postupů vhodným automatizovaným řešením. Nové řešení by mělo poskytnout vysoký stupeň přesnosti při zjišťování kvality textilií. Automatický systém využije zejména zdroje počítačového vidění k detekci nepravidelností ovlivňujících kvalitu plošných textilií.

Předmětem této disertační práce je příspěvek k rozvoji metod analýzy obrazu používaných pro hodnocení textilií z pohledu jejich homogenity, vad a náhodných odchylek od struktury, tj. charakteristik ovlivňujících kvalitu plošných textilií. Práce je zaměřená především na kontrolu kvality v tkaných textiliích. Cílem práce je nalézt vhodné metody a optimalizovat postupy pro detekci nejběžnějších typů vad vyskytujících se ve tkanině, vytvořit vhodné efektivní výpočetní algoritmy a ověřit jejich funkčnost. Metody analýzy budou směřovány především k metodám založeným na texturních charakteristikách získaných zejména ze statistického a spektrálního přístupu.

Obraz povrchu tkaniny, vzhledem k jeho pravidelné, periodické struktuře, je obecně považován za texturní obraz. Přítomnost defektu, nepravidelnosti nebo vady způsobuje porušení této struktury. Automatický systém detekce obvykle vypočítá sadu texturních charakteristik v prostorové nebo frekvenční oblasti pro neporušenou strukturu. Monitorování defektních oblastí je pak založeno na technice posuvného okna, které hledá významné odchýlení hodnot charakteristik od hodnot příslušející struktuře neporušené. Regulační diagramy pro více proměnných jsou použity jako nástroj pro posuzování přítomnosti nepravidelností nebo defektů ve struktuře. Pro vývoj algoritmů jsou vyvinuty procedury pro generování textur jako obrazů textilních materiálů včetně generování některých typů vad. Metody pro detekci vad budou testovány a aplikovány na běžné typy vad, a to jak v simulovaných strukturách tak i v strukturách reálných. Reálné struktury představují nebarvené nebo jednobarevné tkaniny v plátňové nebo keprové vazbě.

2. Přehled současného stavu problematiky

Obraz struktury tkaniny můžeme obecně považovat za typický texturní obraz. V posledních letech je problém automatické detekce defektů ve tkanině v pozornosti mnoha pracovišť. I když bylo navrženo mnoho různých přístupů pro automatizaci, detekce defektů se stále provádí převážně manuálně. Tato disertační práce se zaměřuje na problém detekce běžných vad, které se objevují ve tkanině s využitím technik texturní analýzy.

Počátky texturní analýzy lze nalézt ve druhé polovině minulého století v práci *Haralicka et al.* (viz [1]), kde se autoři snaží nalézt množinu číselných charakteristik, které bychom mohli použít pro klasifikaci nebo kategorizaci obrazových dat (textur). Texturní charakteristiky získané z obrazu jsou založeny na vzájemné prostorové závislosti úrovní šedi dvojic obrazových bodů. Popis této závislosti vychází z tzv. matice vzájemných šedotónových

závislostí, která se počítá pro různé úhly a vzdálenosti mezi dvěma obrazovými body. Na základě této matice bylo definováno 14 texturních charakteristik (příznaků), které slouží k charakterizaci textury, jako jsou např. homogenita, kontrast nebo přítomnost organizované struktury v obraze. Další charakteristiky popisují komplexnost a povahu přechodů úrovní šedi v obraze. Navržené texturní charakteristiky byly použity ke klasifikaci mikrofotografií pískovce, leteckých a satelitních snímků zemského povrchu.

Carstensen ve své práci [2] testoval účinnost 15 texturních charakteristik získaných z matic vzájemných šedotónových závislostí na 15 deterministických a stochastických texturách získaných z databáze *Brodatzových textur* [25] pomocí metody CART. Zároveň se hledala charakteristika, která nese největší diskriminační informaci. Výsledky prokázaly, že nejdůležitější texturní charakteristikou z pohledu rozlišovací schopnosti je kontrast.

V práci [3] se *Lin* zabýval aplikací matic vzájemných šedotónových závislostí na automatickou kontrolu dostavy tkaniny. Na základě digitálních obrazů získaných ze skeneru byly určeny matice vzájemných šedotónových závislostí. Z matic byla vypočtena texturní charakteristika kontrast a vynesena do grafu závislosti kontrastu na vzdálenosti obrazových bodů. Z grafů byly vyhodnocené dostavy jednotlivých vazeb a ty autor porovnal s hodnotou dostavy, která byla získaná páráním. Výsledky této práce ukázaly, že použití texturní analýzy pro určování dostavy tkaniny je vhodné jen pro nebarvené nebo jednobarevné tkaniny s plátňovou vazbou. Výhodou navržené metody je především její nedestruktivnost a relativní rychlost, i když nelze hovořit o úplně automatické metodě.

Rozpoznáním defektů ve tkanině s využitím matic vzájemných šedotónových závislostí se zabývala práce *Ku & Su* [4]. Autoři se zaměřili na defekty typu olejová skvrna, díra, přetržená útková nit, přetržená osnovní nit. Z normalizované matice vzájemných šedotónových závislostí pro jednotlivé obrazy byly vyextrahovány 4 charakteristiky (energie, entropie, kontrast, rozdílnost). Na základě relační analýzy úrovní šedi byla zjištěna korelace mezi charakteristikami získanými z obrazů tkaniny bez defektu a obrazů s defektem a klasifikován vstupní obraz do kategorií.

Přehled metod pro detekci vady ve tkanině a analýza jejich vhodnosti pro detekci konkrétních vad byla provedena v práci *Bodnarová et al.* [5]. Jedna z metod byla metoda založená na maticích vzájemných šedotónových závislostí. Z matic bylo získáno 5 charakteristik: energie, entropie, lokální homogenita, korelace a kontrast. V první „trénovací“ fázi byly zjišťovány optimální charakteristiky pro určitou tkaninu ze vzorků bez defektů. Ve druhé „testovací“ fázi byly vypočteny stejné charakteristiky pro vzorky, které potenciálně obsahovali vady. Pravděpodobnost přítomnosti vady v obraze byla pak odhadována na základě χ^2 testu.

Statistické metody je možné taky použít pro sledování nestejnoměrnosti uspořádání textilního materiálu. *Linka & Volf* [6] na základě získaných texturních charakteristik 2. řádu provedli klasifikaci nehomogenity rozložení materiálu v netkané textilií pomocí metody CART. Výsledky byly srovnány s metodou, kde byla použita klasifikace na základě odhadů parametrů Markovského náhodného pole.

Algoritmus založený na jednoduchém statistickém měření, prahování a morfologických operacích je popsán v pracích *Anagnostopoulos et al.* [7] a [8]. Rychlý algoritmus je navržen s ohledem na kontrolu kvality v reálném čase. V první fázi algoritmus provádí normalizaci obrazu a korekci nerovnoměrného osvětlení v ploše obrazu. Další postup je založen na myšlence, že rozdíl mezi směrodatnými odchylkami sousedních bloků by se neměl výrazně měnit. Výsledkem této části algoritmu je detekování možných neregulérních oblastí v normalizovaném obraze. Poslední část algoritmu s využitím morfologických operací přesně popisuje tvar detekovaných defektů. Výsledky potvrzují vysokou přesnost detekce.

Použitelnost Fourierovy transformace k měření vizuálních charakteristik regulárních periodických vzorů popsal *Wood* v práci [9]. Autor zde popisuje Fourierovu a související transformace a jejich využití při charakterizaci kobercových vzorů.

Objektivní měření vzhledu tkaniny na základě Fourierovy transformace zkoumali *Ravandi & Toriumi* v práci [10]. V práci byly zkoumány charakteristiky povrchu tkaniny, jako směrovost, dostava, periodičita útkových a osnovních nití v plátňové vazbě. Autoři zde poskytli nový přístup k hodnocení vzhledu tkaniny.

Obrazovou analýzou tkaniny s chybějící útkovou nebo osnovní nití se zabývá práce *Jasper & Potlapalli* [11]. Autoři porovnávali tři techniky: Sobelův hranový operátor, Fourierovu transformaci a diskrétní vlnkovou transformaci. Výsledky prokázali, že vlnková transformace charakterizuje defekty typu chybějící nit rychleji a přesněji než zbylé dvě metody.

Aplikaci technik založených na Fourierově transformaci k identifikaci vazby, dostavy tkaniny, zešíkmení a dalších strukturních charakteristik tkanin popisuje *Xu* v práci [12]. Jsou rozpoznávány základní typy vazeb (plátňová, keprová, atlasová atd.) sledováním vrcholů ve výkonovém spektru, které korespondují s periodickou povahou obrazů tkanin. Měření směrovosti periodických elementů je realizováno na základě radiální a úhlové funkce získané z výkonového spektra.

Automatickým rozpoznáváním vazby tkaniny se zabýval *Kang et al.* v práci [13]. Navrhnutý algoritmus rozpoznává jednak vazbu tkaniny, ale také barvu přízí. Osnovní i útkové vazné body a velikost přízí jsou detekovány změnou úrovně šedi v horizontálním a vertikálním směru z obrazu tkaniny získaného z propuštěného světla. Osnovní a útkové vazné body jsou pak určeny po analýze poměru stran objektů ve tvaru elipsy ve vazném bodu. Z obrazu tkaniny získaného z odraženého světla je určena vazba tkaniny.

Detekci a klasifikaci 4 typů defektů (dvoják, chybějící nit, díra, nepravidelná dostava) s využitím dvojrozměrné Fourierovy transformace se zabývali *Chan & Pang* v práci [18]. Dva centrální frekvenční diagramy byly vyextrahovány z frekvenčního spektra. Ke klasifikaci je využito sedm parametrů založených na nejvýznamnějších frekvencích ve dvou směrech. Parametry jsou vypočteny pro obraz struktury bez defektu a obraz stejné struktury s defektem. Rozdíl v parametrech může být použitý pro klasifikaci jednotlivých typů vad. Metoda je testována na simulovaných i reálných datech.

Globální přístup k automatické kontrole defektů na statistických obrazech textur prezentovali *Tsai & Huang* v příspěvku [16]. Tyto textury zahrnovaly obrazy smirkového papíru, slitiny, kůže a dalších průmyslových materiálů. Navrhnuté metody využívají rekonstrukci obrazu použitím Fourierovy transformace. Povrch statistických textur vykazuje náhodnou povahu, strukturu, tvar frekvenčních komponent ve frekvenčním spektru je přibližně izotropní, přibližující se kruhu. Nalezením vhodného poloměru kruhové oblasti v ploše spektra a nastavením frekvenčního spektra mimo tuto oblast na nulu byla odstraněna periodičita, opakování vzoru statistických textur. Obnovený obraz byl získán použitím inverzní diskrétní Fourierovy transformace. Po odstranění periodicity měl obnovený obraz přibližně stejné hodnoty úrovně šedi, ale defekty byly jednoznačně určeny následným prahováním do binárního obrazu. Tento přístup převedl náročnou detekci vady na úlohu jednoduchého prahování. Výsledky potvrdily účinnost metody na různých reálných statistických texturách.

Stejní autoři řešili podobně problém automatické kontroly povrchu ve svém starším příspěvku o směrových texturách (viz [17]). Rozdíl oproti předchozímu přístupu byl v tom, že směrové linie texturního vzoru v obraze byly určeny použitím jednorozměrné Houghovy transformace. Nastavením těchto vysokofrekvenčních hodnot na nulu a následným provedením inverzní transformace byl obraz obnoven. Tímto postupem byla odstraněna směrová textura a v obraze bylo možno jasně definovat porušení nebo vadu. Účinnost metody byla ověřena na obrazech tkanin, dřeva a různých jiných površích.

Modelováním struktury tkaniny se zabývají práce *Chan & Pang* [18] a *Escofet et al.* [19]. K modelování struktury tkaniny se využívá konvoluční věta, kde elementární jednotka s minimálním počtem překřížených nití a funkce vzoru opakování elementární jednotky je využita k vytvoření struktury tkaniny. Obrazy struktury jsou však pouze binární.

3. Použité metody

3.1. Textura

Textura je často používaný a implicitně chápaný pojem. Každý člověk si pod pojmem textura něco představí, má svoji vlastní interpretaci pojmu textury. Explicitní definice textury ale chybí, textura jednoduše existuje. Člověk obvykle popisuje určitou texturu slovy jako jemná, drsná, hladká, hrubá a podobně. Tyto atributy jsou instinktivně jasné, avšak stále relativní a ne snadno měřitelné. Slovo textura pochází z latinského slova *textura*, které znamená tkanina, látka. Pod pojmem textura se podle slovníku *Dictionary of the English Language* (viz [22]) rozumí:

1. Struktura protkaných vláken nebo jiných elementů.
2. Charakteristická stavba nebo struktura něčeho, hlavně vzhledem na velikost, tvar a uspořádání jeho částí: *textura písčité půdy*, a pod.

Když zaměníme „vlákna“ za „pixely“, tak uvedenou definici je možné aplikovat na obrázky. Z toho vyplývá, že textura je typ obrazu, kterého hlavním znakem je určitá struktura nebo prostorové uspořádání. Textury se obecně dělí do dvou hlavních skupin: strukturní a statistické (viz *Tsai & Huang* [16]). Strukturní textury jsou takové, které jsou složeny z opakování základních texturních prvků, jako jsou např. orientované linie, jejich rozmístění je určeno nějakým pravidlem. Takovéto textury se objevují například u plošných textilií. Statistické textury nejsou popsány opakujícími se prvky a pravidlem rozmístění. Rozdělení úrovní šedi v obrazech takovýchto textur je náhodné, lze je zhruba popsat nějakým pravděpodobnostním rozdělením. Mezi takovéto textury je možné zařadit smírkový papír, písek, kůži atd. Textura je přirozená vlastnost prakticky všech povrchů a obsahuje důležité informace o jejich strukturním uspořádání (viz *Haralick et al.* [1]). Texturní analýza je důležitou součástí počítačového zpracování obrazu, která se zabývá především analýzou obrazů povrchů. Jedním z problémů analýzy textur je fakt, že stejný povrch může vykazovat různé textury při pořízení snímků povrchu při různých podmínkách, například při rozdílném zvětšení, při rozdílné poloze světelného zdroje. Z toho vyplývají dvě důležité vlastnosti textury, a to: snímání obrazu textury je závislé na měřítku a obraz textury je závislý na světelných podmínkách. Hlavním cílem texturní analýzy je získat „vhodné“ texturní informace z obrazu textury. Texturní analýza se snaží vyřešit tři základní problémy spojené s obrazem textur (viz *Petrou & Sevilla* [24]):

- **Texturní klasifikaci**, jež se zabývá analyzováním obrazu získaného z povrchu a jejímž cílem je identifikovat nebo popsat, co obraz povrchu reprezentuje.
- **Texturní segmentaci**, která rozděluje obraz na oblasti, které obsahují různé, ale homogenní textury.
- **Detekce defektů a změn v textuře**, jež řeší otázku, jestli je obraz textury homogenní nebo obsahuje porušení, tj. defekty.

Tři nejběžnější přístupy k analýze textur jsou:

- **Statistický přístup**, který charakterizuje texturu na základě statistických charakteristik rozdělení úrovní šedi obrazových bodů, které tvoří obraz povrchu textury. Tyto charakteristiky jsou vypočteny z histogramu úrovní šedi nebo z matice vzájemných šedotónových závislostí obrazu textury.
- **Strukturní příznaky**, které charakterizují texturu jako obraz složený z jednoduchých primitiv nazývaných textury (texturní elementy), které jsou pravidelně uspořádané

podle určitých pravidel. Primitiva jsou oblasti, které tvoří jednotlivé pixely nebo skupina sousedních pixelů, které mají podobné úrovně šedi.

- **Spektrální přístup**, který je založen na vlastnostech Fourierova spektra a popisuje globální periodicitu úrovně šedi obrazu identifikováním vysokých hodnot frekvenčních komponent v obraze spektra ve frekvenční oblasti. Fourierovo spektrum je vhodné pro popis směrovosti periodických nebo téměř periodických vzorů v monochromatických obrazech textury.

Tato disertační práce se věnuje hodnocení plošných textilií především s ohledem na detekci vad ve tkaninách. Tkaniny mají periodickou strukturu následkem charakteristického tkacího procesu použitého při jejich vzniku. Důsledkem pravidelné periodické podstaty tkanin je pravidelná změna intenzity šedé stupnice v obraze jejich povrchu. Tato dvojrozměrná periodická změna v intenzitě je charakteristickou vlastností textury, tj. obraz povrchu tkaniny je možné zařadit mezi textury a k analýze takovýchto obrazů je vhodné použít metody texturní analýzy. Detekce defektů ve tkanině bude testována na obrazech simulovaných struktur i obrazech reálných struktur. Defekty budou zahrnovat některé typy běžných defektů vyskytujících se ve tkanině, které způsobují porušení struktury. Metody budou založeny zejména na statistickém a spektrálním přístupu.

3.2. Běžné vady tkaniny

V textilní terminologii (viz *Textile Dictionary* [26]) je defekt definován jako „chyba která by mohla degradovat očekávané provedení textilního materiálu, nebo když se objeví na nápadném místě v textilním výrobku, mohla by být snadno viditelná a výrobek by mohl být zamítnut potenciálním zákazníkem“. Takže defekt (vada) je ve skutečnosti nějaká viditelná odchylka od předpokládaného normálu a způsobuje snížení kvality výsledného výrobku. Přítomnost defektů ve výsledné tkanině může být přisuzována mnoha faktorům. Defekty ve tkanině mohou být výsledkem nedokonalosti vláken nebo příze, chyby v průběhu tkacího procesu nebo během barvení anebo jiných zušlechťovacích procesů. Různých typů defektů ve tkanině je mnoho, základní typy se stručnou charakteristikou můžeme nalézt v katalogu *ITS Publishing* [27] a v normách ČSN [28], [29]. Vady ve tkanině je možné rozdělit přibližně do tří skupin. Vady ve směru útku, vady ve směru osnovy a vady nezávislé na směru.

- **Vady v útkovém směru**
 - Nadměrná dostava útkových nití (útkový pruh)
 - Nedostatečná dostava útkových nití (nedoraz)
 - Zátah
 - Odlišná nit (dvoják)
 - Zatkaný předmět (cizí těleso)
 - Přetržená útková nit (nedolet)
- **Vady v osnovním směru**
 - Nepravidelná osnovní dostava (osnovní pruh)
 - Stopy po jehličkách
 - Vadný návlek (osnovní dvoják)
 - Přetržená osnovní nit
- **Vady nezávislé na směru**
 - Vzhledová vada
 - Skvrna


- Vada nitě (tlusté, tenké místo)
- Zátrh
- Vazbová vada
- Smyčka
- Díra
- Volná nit
- Flotáž (nadhozy, podhozy)
- Uzel
- Odřené místo
- Záhyb

3.2.1. 2D vizualizace ideální vazby tkaniny

K testování algoritmů detekce vad bylo vhodné vytvořit dvojrozměrný model vazby tkaniny se simulovanými běžnými defekty. K vytvoření periodické modelové struktury tkaniny je možné využít dvojrozměrnou diskrétní konvoluční větu. Výstupní obraz modelu struktury tkaniny $g(x,y)$ je možné simulovat konvolucí základního opakujícího se prvku, střídy vazby $b(x,y)$, který představuje konvoluční masku a vstupního obrazu sítě $h(x,y)$, který představuje opakování střídy. Potom konvoluce, označována \otimes , je dána vztahem (viz např. *Chan & Pang* [18], *Escofet et al.* [19], *Gonzales & Wood* [21])

$$g(x, y) = b(x, y) \otimes h(x, y) = \sum_{m=0}^x \sum_{n=0}^y b(m, n) h(x - m, y - n). \quad (3.1)$$

Střída vazby tkaniny je taková část vazby, která se v celé ploše s výjimkou krajů tkaniny pravidelně opakuje a je vytvořena skládáním osnovních a útkových vazných bodů v závislosti od typu vazby. Vazné body je možné generovat na základě vstupních parametrů p_{wa} , p_{we} představujících rozteč osnovních resp. útkových nití a d_{wa} , d_{we} charakterizujících průměr (šířku) osnovních resp. útkových nití v pixelech. Parametr sp vyjadřuje šířku hranice nitě taktéž v pixelech. Vzhled vazby tkaniny je možné ještě měnit dalšími dvěma parametry stínování, a to *stín nití* a *stín provázání*, hodnoty jsou v intervalu 0 - 1. Na obrázku 3.1(a) je vidět střídu plátňové vazby, kterou tvoří dvě osnovní a dvě útkové nitě, obrázek 3.1(b) zobrazuje síť soustavy bodů opakování střídy vazby. Výsledek konvoluce masky a sítě je možné vidět na obrázku 3.1(c) a představuje plošný model plátňové vazby o velikosti $n = 200$ pixelů s nastavenými vstupními parametry $p_{wa} = 16$, $p_{we} = 20$, $d_w = d_{we} = 12$ a $sp = 1$ v pixelech. Z důvodu lepšího přiblížení reálným snímkům je možné k vygenerovaným obrázkům přidat ještě Gaussovský šum.




Obrázek 3.1 (a) Konvoluční maska (střída plátňové vazby), (b) soustava bodů opakování střídy vazby, (c) výsledek konvoluce masky a sítě.

3.2.2. Simulace běžných defektů ve tkanině v plátnové vazbě


Ukázka obrázků některých simulovaných běžných typů vad v plátnové vazbě je na obrázcích 3.2(a)-(i). Obrázky defektů byly modelovány na základě algebraických a morfologických operací obrazů plátnové vazby. Pozice, velikost a tvar defektů je náhodně generována. Pro simulaci bylo vytvořeno uživatelské rozhraní v programu *MATLAB* [20].

3.2.3. Reálné vady ve tkanině

K získání obrázků defektů v reálné tkanině se použil skener. Obrazy byly snímány při rozlišení 400 dpi. Všechny výstupní obrazy byly uloženy jako obrazové matice o velikosti 500 x 500 obrazových bodů v 8-bitové hloubce (256 úrovní šedi). Ke zvýšení kontrastu se použila metoda vyrovnání (ekvalizace) histogramu. Na obrázcích 3.3(a)-(f) jsou snímky běžných vad objevujících se v reálných strukturách tkaniny.



Obrázek 3.2 Simulované vady v plátnové vazbě, (a) tlustá nit - útek, (b) přetržené útkové nitě, (c) nedostatečná dostava - útek, (d) díra, (e) přetržená osnovní nit, (f) tlustá nit – osnova, (g) skvrna, (h) přetržená osnovní nit, (i) tlustá nit – osnova.



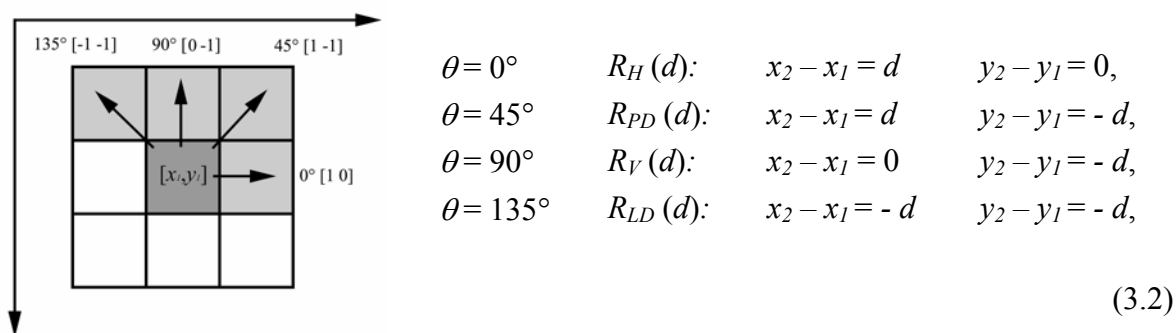
Obrázek 3.3 Reálné vady ve tkanině, (a) nadměrná dostava - útek, (b) nedostatečná dostava - útek, (c) odlišná nit - útek, (d) skvrna, (e) zatkaný předmět, (f) vada nitě - osnova.

3.3. Statistický přístup

Statistický přístup charakterizuje texturu na základě texturních charakteristik zjištěných z obrazu textury. Texturní statistiky rozdělujeme na charakteristiky prvního řádu, druhého řádu a vyšších řádů.

- **Charakteristiky prvního řádu** se vztahují k marginálnímu rozdělení úrovně šedi a vypočítávají se ze zjištěných četností jednotlivých úrovní šedi v obraze. Jestliže si teda digitalizovaný obraz představíme jako nějaké rozdělení pravděpodobnosti, tak vhodnými charakteristikami budou charakteristiky tohoto rozdělení, například odhad střední úrovně šedi, odhad rozptylu úrovně šedi, odhad šikmosti úrovně šedi atd. Určitému obrazu je přiřazen jeden histogram. Jednomu histogramu však může odpovídat několik obrazů, například při změně polohy objektu. Z toho vyplývá, že charakteristiky prvního řádu poskytují informaci jenom o rozdělení úrovně šedi v obraze, o prostorovém uspořádání jednotlivých pixelů nikoliv.
- **Charakteristiky druhého řádu** vypovídají o vztahu (závislosti) úrovně šedi mezi sousedními body v obraze a můžeme je chápat jako charakteristiky dvourozměrného rozdělení pravděpodobnosti. Základem je matice vzájemných šedotónových závislostí (GLCM, *Gray Level Cooccurrence Matrix*), taktéž nazývaná matice plošných šedotónových závislostí, která nese globální informaci o obraze a z této matice budou vypočtené charakteristiky druhého řádu. Charakteristiky druhého řádu jsou založené na prostorovém uspořádání bodů v obraze a jsou vhodné pro popis textury. Pro výpočet charakteristik získaných z textury předpokládáme, že textura (resp. část, ze které získáme charakteristiky) je homogenní, tj. že vypočtené hodnoty texturu skutečně reprezentují.

Matrice plošných šedotónových závislostí je čtvercová matice, c , o rozměrech daných počtem úrovní šedi v obraze. Je definována vzhledem ke dvěma parametrům, d značí vzdálenost mezi dvěma obrazovými body a θ znamená příslušný úhel mezi dvěma obrazovými body (x_1, y_1) a (x_2, y_2) . Celkem existuje celkově 8 pozičních uhlů mezi dvěma sousedními pixely. Při předpokladu symetrie vzájemných vztahů sousedních bodů vystačíme jen se 4 směry ($\theta = 0^\circ, 45^\circ, 90^\circ, 135^\circ$). Relativní pozice R mezi dvěma pixely je definována (viz Lin [3], Kuo & Su [4])



Obrázek 3.4 Relativní pozice mezi dvěma pixely pro $d = 1$.

Na základě uvedených pozic, vztah mezi dvojicí pixelů a počet výskytů úrovní šedi i a j vzhledem k parametrům d a θ je dán

$$\begin{aligned}
 c_{ij}(d, 0^\circ) &= \# \{R_H(d), f(x_1, y_1) = i, f(x_2, y_2) = j\}, \\
 c_{ij}(d, 45^\circ) &= \# \{R_{PD}(d), f(x_1, y_1) = i, f(x_2, y_2) = j\}, \\
 c_{ij}(d, 90^\circ) &= \# \{R_V(d), f(x_1, y_1) = i, f(x_2, y_2) = j\}, \\
 c_{ij}(d, 135^\circ) &= \# \{R_{LD}(d), f(x_1, y_1) = i, f(x_2, y_2) = j\}.
 \end{aligned}
 \tag{3.3}$$

kde index H značí horizontální směr, PD je pravý diagonální směr, V označuje vertikální směr a LD levý diagonální směr. Symbol $\#$ značí celkový počet párů pixelů. Tato informace se uchovává v matici plošných šedotónových závislostí c , c_{ij} značí prvek této matice daný vztahem (3.3). V praxi se často volí pro d hodnota 1, jak je vidět na obrázku 3.4. Jestliže N_h je celkový počet dvojic (výskytů) pro d a θ v matici plošných šedotónových závislostí c , pak $C_{ij} = c_{ij}/N_h$ označuje prvky normalizované matice plošných šedotónových závislostí C , která odhaduje sdružené rozdělení úrovní šedi v závislosti na d a θ . Matice plošných šedotónových závislostí počítáme pro různé vzdálenosti pixelů d a různé poziční úhly θ . Poskytují množství informací, ale zároveň se však jedná o velké množství dat. Pro obraz s 256-ti úrovní šedi má matice plošných šedotónových závislostí $256^2 = 65536$ prvků. Redukce dat je možné docílit například snížením počtu úrovní šedi.

Z normalizované matice plošných šedotónových závislostí můžeme obdržet mnoho charakteristik. Standardní sada obsahuje 15 charakteristik (viz Haralick et al. [1], Carstensen [2]). Metoda klasifikačních a regresních stromů (CART, Classification and Regression Trees) byla použita ke klasifikaci vad na vybraných sadách simulovaných obrazů různých typů defektů s využitím všech 15 charakteristik druhého řádu. Cílem klasifikace je redukce všech texturních charakteristik druhého řádu na menší podskupinu charakteristik a získání informace, které mají největší rozlišovací sílu. Na základě výsledků klasifikace, které lze nalézt v disertační práci byla vybrána sada pěti charakteristik, které budou dále použity k detekci vad v obrazech tkanin. Jedná se o následující charakteristiky.

- **Energie (Druhý angulární moment)**

$$\varepsilon = \sum_{i=0}^{G-1} \sum_{j=0}^{G-1} C_{ij}^2 . \quad (3.4)$$

- **Korelace (Autokorelace)**

$$\rho = \sum_{i=0}^{G-1} \sum_{j=0}^{G-1} \frac{(i - \mu_x)(j - \mu_y)C_{ij}}{\sigma_x \sigma_y} . \quad (3.5)$$

- **Lokální homogenita**

$$IDM = \sum_{k=0}^{G-1} \frac{D_k}{1 + k^2} . \quad (3.6)$$

- **Odhad třetího momentu rozdělení součtů úrovní šedi**

$$A = \sum_{k=0}^{2G-2} (k - SA)^3 S_k . \quad (3.7)$$

- **Odhad čtvrtého momentu rozdělení součtů úrovní šedi**

$$B = \sum_{k=0}^{2G-2} (k - SA)^4 S_k . \quad (3.8)$$

3.4. Spektrální přístup

Dvourozměrná diskretní Fourierova transformace, zkráceně 2D DFT (*2 Dimensional Discrete Fourier Transform*) patří mezi spektrální techniky, které popisují textury pomocí frekvenční oblasti. Tyto techniky jsou založené na vlastnostech Fourierova obrazu spektra a popisují globální periodicitu úrovní šedi obrazu identifikováním vysokých frekvenčních hodnot ve spektru. Fourierovo spektrum je vhodné pro popis směrovosti periodických nebo téměř periodických vzorů v monochromatických obrazech textury. Směrový charakter monochromatických obrazů jasně koresponduje s vysokými hodnotami frekvenčních komponent, které jsou rozloženy podél přímých směrů v obraze spektra (ve frekvenční oblasti). Fourierova transformace není invariantní vzhledem k rotaci, tzn. rotací originálního obrazu podle daného úhlu bude frekvenční rovina otočená o stejný úhel. Transformace horizontálních směrů (převažujících směrů jasových rozhraní v obrázku - gradientu obrazové funkce) v původním obraze se jeví jako vertikální směr vysokých hodnot frekvenčních komponent v obraze výkonového spektra, tj. význačné směry v původním obraze a jejich transformace v obraze spektra jsou navzájem ortogonální.

Nechť $f(x,y)$ je obrazová funkce pro $x = 0, 1, 2, \dots, m - 1$ a $y = 0, 1, 2, \dots, n - 1$, kde $m \times n$ označuje velikost obrazu. Dvojměrná diskretní Fourierova transformace obrazové funkce $f(x,y)$ je dána vztahem (viz např. *Tsai & Huang [17]*, *Gonzales & Wood [21]*)

$$F(u,v) = \sum_{x=0}^{m-1} \sum_{y=0}^{n-1} f(x,y) e^{-j2\pi(ux/m+vy/n)} , \quad (3.9)$$

pro $u = 0, 1, 2, \dots, m - 1$ a $v = 0, 1, 2, \dots, n - 1$. Frekvenční oblast je souřadný systém s frekvenčními proměnnými u a v . Analogicky je definovaná prostorová oblast se souřadným

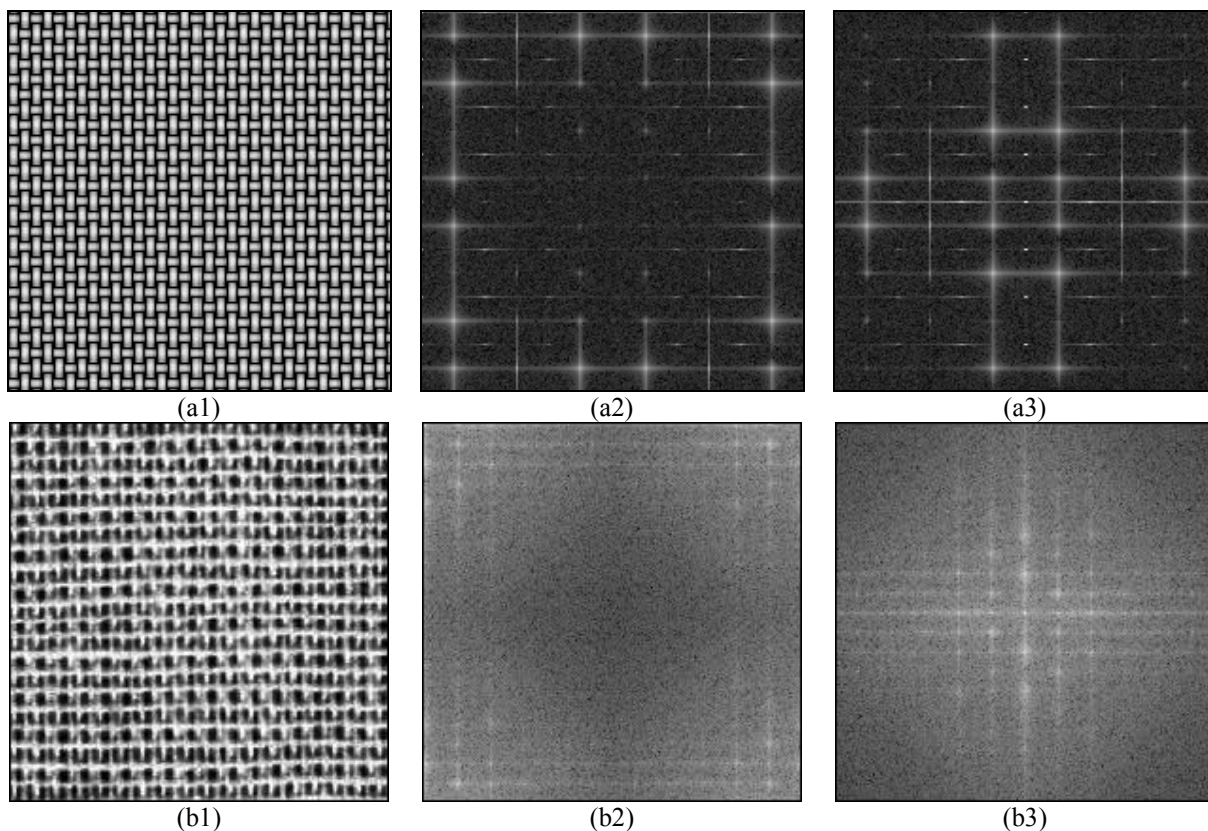
systemem s prostorovými proměnnými x a y . Pravoúhlá oblast $m \times n$ definovaná pomocí $u = 0, 1, 2, \dots, m - 1$ a $v = 0, 1, 2, \dots, n - 1$ je označována frekvenční pravoúhelník. Je zřejmé, že frekvenční pravoúhelník má stejný rozměr jako vstupní obraz. Dvojměrná inverzní diskretní Fourierova transformace, zkráceně 2D IDFT (*2 Dimensional Inverse Discrete Fourier Transform*) má tvar

$$f(x, y) = \frac{1}{mn} \sum_{u=0}^{m-1} \sum_{v=0}^{n-1} F(u, v) e^{j2\pi(ux/m + vy/n)}, \quad (3.10)$$

pro $x = 0, 1, 2, \dots, m - 1$ a $y = 0, 1, 2, \dots, n - 1$. Když je dána $F(u, v)$ pomocí 2D IDFT získáme $f(x, y)$. Funkční hodnoty $F(u, v)$ se nazývají Fourierovy koeficienty rozvoje. Hodnota transformace v počátku frekvenční oblasti se nazývá *DC* (*Direct Current*) komponenta Fourierovy transformace a je rovná mn x průměrná hodnota šedi v obraze. Jestliže $f(x, y)$ je reálná funkce, její transformace je funkce komplexní. Z důvodu analýzy transformace je vhodné spočítat její spektrum (hodnotu $F(u, v)$) a zobrazit jako obraz. Výkonové spektrum je definované jako druhá mocnina hodnoty $|F(u, v)|$. Protože dynamický rozsah hodnot spektra je příliš veliký, proto je pro $P(u, v)$ ve škále úrovní šedi v 8-bitové hloubce provedena logaritmická transformace (viz *Gonzales & Wood* [21]), která je definovaná

$$P(u, v) = \log(1 + |F(u, v)|^2). \quad (3.11)$$

Obrázky 3.5(a1),(b1) zobrazují originální obraz plátňové vazby simulovaný, resp. reálný. Obrázky 3.5(a2),(b2) představují výkonová spektra originálních obrazů po logaritmické transformaci, obrázky 3.5(a3),(b3) jsou centrovaná výkonová spektra po logaritmické transformaci, kde počátek transformace $F(0,0)$ je přesunutý do středu frekvenčního pravoúhelníku.



Obrázek 3.5 (a1),(b1) Originální obrazy plátňové vazby, (a2),(b2) výkonová spektra po logaritmické transformaci, (a3),(b3) centrovaná výkonová spektra po logaritmické transformaci.

4. Přehled dosažených výsledků

4.1. Detekce vad s využitím charakteristik 2. řádu

Cílem finální analýzy hodnocení kvality plošných tkaných textilií je účinná a efektivní detekce defektních a nedefektních oblastí v jejich obraze. K automatické detekci defektních oblastí je využita technika současného monitorování více texturních charakteristik, individuální sledování těchto charakteristik může poskytovat nedostatečné výsledky. Proces monitorující kvalitu, která je charakterizována vektorem několika proměnných, je známý jako vícerozměrná statistická regulace procesu (MSCP, *Multivariate Statistical Process Control*). Nástrojem vícerozměrné statistické regulace procesu jsou Hotellingovy regulační diagramy, které využívají statistiky D^2 a jsou zobecněním Shewhartových regulačních diagramů typu \bar{x} . Statistika D^2 je ekvivalentní druhé mocnině Mahalanobisovy vzdálenosti.

V první fázi se analýza zaměřila na zjištění optimálních statistických charakteristik vypočtených z matic plošných šedotónových závislostí, které přísluší neporušené simulované struktuře povrchu tkaniny. Na základě vyhodnocení v předchozí kapitole bylo zjišťováno pět významných statistických charakteristik (energie, korelace, lokální homogenita, třetí a čtvrtý moment rozdělení hodnot součtů úrovní šedi) získaných z GLCM s parametry ($d = 1$ a $\theta = 0^\circ$, směr útku) a pět charakteristik z GLCM s parametry ($d = 1$ a $\theta = 90^\circ$, směr osnovy). Vektor charakteristik \mathbf{X}_i byl vypočten pro 1000 náhodně umístěných oken o velikosti 50 x 50 pixelů v simulovaném obraze struktury tkaniny ($m = 1000$ pozorování, $p = 10$ charakteristik). Bylo ověřeno, že data pochází z vícerozměrného normálního rozdělení, tj. byla získána matice m pozorování p -rozměrného normálního rozdělení, výběrový průměr $\bar{\mathbf{X}}$ a výběrová kovarianční matice S tohoto rozdělení. Z dat byla vypočtena horní regulační mez UCL podle vztahu (viz např. Zamba & Hawkins [31], Bersimis et al. [32], Mason et al. [33])

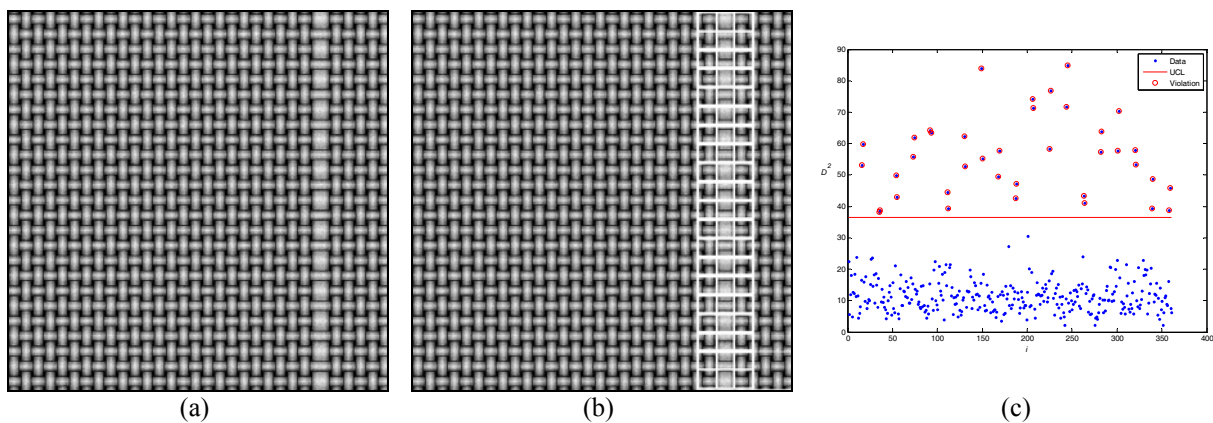
$$UCL = \frac{p(m+1)(m-1)}{m(m-p)} F_{p, m-p}(1-\alpha), \quad (4.1)$$

kde $F_{p, m-p}(1-\alpha)$ je $(1-\alpha)$ kvantil F -rozdělení s parametry p a $(m-p)$. Technika regulačních diagramů potom byla použita pro monitorování defektních oblastí. Posuvné okno o velikosti 50 x 50 pixelů se systematicky po kroku 25 pixelů posouvalo po celé ploše obrazu o velikosti 500 x 500 pixelů (simulace kontinuálního průběhu). Pro každé okno byla napočtena i -tá testová statistika podle vztahu

$$D_i^2 = (\mathbf{X}_i - \bar{\mathbf{X}})^T S^{-1} (\mathbf{X}_i - \bar{\mathbf{X}}) \quad (4.2)$$

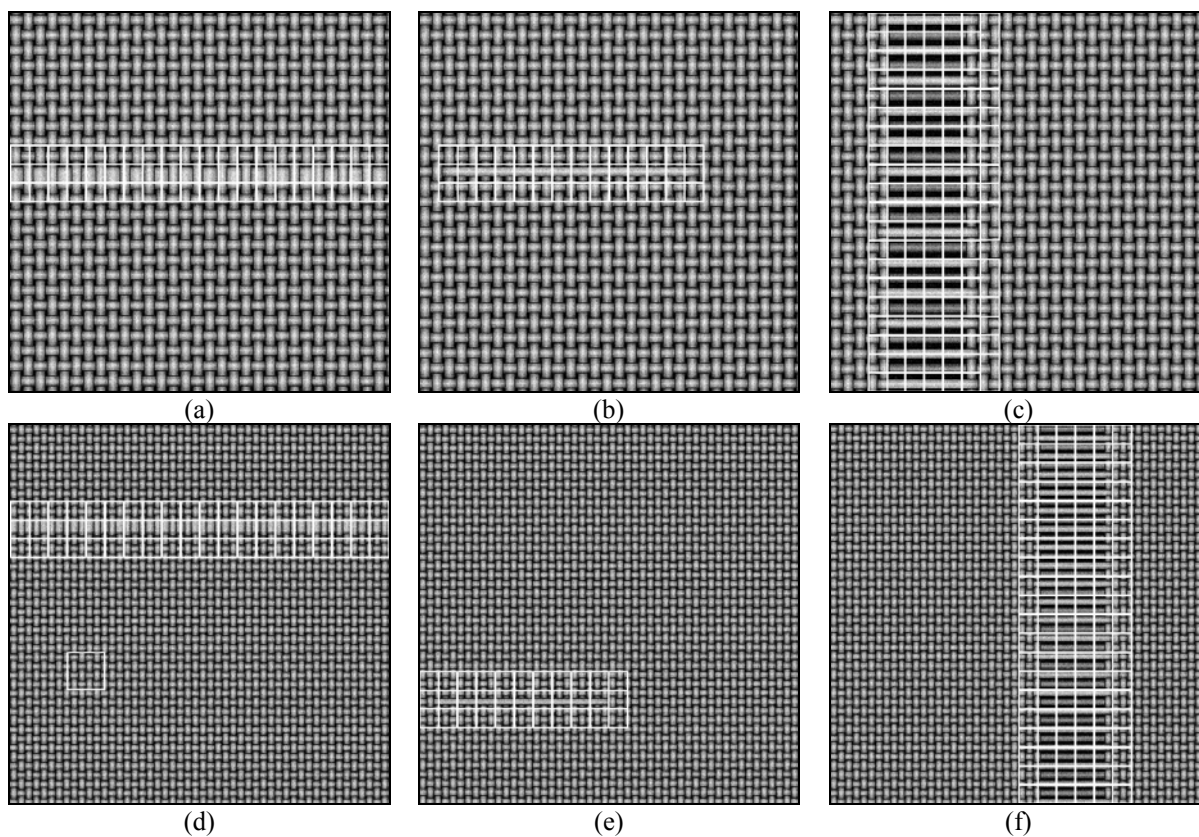
a vynesena proti horní regulační mezi UCL . Jestliže i -tá hodnota testové statistiky byla mimo mez, okno bylo považováno za okno obsahující defekt.

Obrázek 4.1(a) zobrazuje defekt v simulované struktuře tkaniny, konkrétně tlustou osnovní nit. Na obrázku 4.1(c) je vynesena i -tá testová statistika. Všechna pozorování (okna) nad horní regulační mezí jsou považována za okna obsahující defekt. Výsledek algoritmu je vidět na obrázku 4.1(b), kde okno zobrazeno bílou barvou je považováno za okno obsahující defekt. Obrázky 4.2(a)-(c) zobrazují výsledek použití algoritmu detekce na simulovaných strukturách obsahujících běžné defekty, obrázky 4.2(d)-(f) ukazují výsledek algoritmu na stejných typech vad, ale s jinými parametry struktury tkaniny.




Obrázek 4.1 (a) Defekt v simulované struktuře (tlustá osnovní nit), (b) výsledek realizace algoritmu, (c) graf i -té statistiky.

Stejná technika monitorování byla využita při detekci vad v reálných strukturách. Podobně jako v předchozím simulovaném případě, obrázek 4.3(a) zobrazuje vadu nedostatečná dostava útku v reálné struktuře, obrázek 4.3(b) ukazuje výsledek detekce, kde okna zobrazená bílou barvou představují okna obsahující defekt, které korespondují s i -tou testovou statistikou překračující UCL . Horní regulační mez na hladině významnosti $\alpha = 0.001$ byla vypočtena pro 1000 náhodně umístěných oken o velikosti 50×50 pixelů v neporušeném obraze reálné struktury tkaniny. Výsledky detekce pro některé další typy vad v reálných strukturách jsou zobrazeny na obrázcích 4.4(a)-(f).




Obrázek 4.2 Výsledek použití algoritmu v simulovaných strukturách: (a),(d) tlustá nit - útek, (b),(e) flotáž - útek, (c),(d) přetržené osnovní nitě.



Obrázek 4.3 (a) Defekt v reálné struktuře (nedostatečná dostava - útek), (b) výsledek realizace algoritmu, (c) graf i -té statistiky.

Ukazuje se, že algoritmus detekce založený na statistických charakteristikách druhého řádu získaných z matic plošných šedotónových závislostí je vhodným pro detekci vad v simulovaných a taktéž v reálných strukturách. Tímto postupem můžeme efektivně detekovat směrové, ale taky nesměrové typy vad. Algoritmus není vhodný pro vady, které nezpůsobují příliš velké změny struktury, jako např. vada dvoják, smyčka nebo flotáž. Metoda je relativně rychlá a mohla by být využita pro kontrolu kvality tkanin v reálném čase. Algoritmus detekce je založený na systematickém prohlížení statického obrazu posuvným oknem. Ve skutečném provozu je tkanina odtahovaná na válec rovnoměrnou rychlostí, v případě online kontroly by byly statické snímače obrazu rozmístěné rovnoměrně nad tkaninou po celé její šířce.



Obrázek 4.4 Výsledek použití algoritmu v reálných strukturách: (a) nadměrná dostava - útek, (b) nedostatečná dostava - útek, (c) odlišná nit - útek, (d) skvrna, (e) zatkaný předmět, (f) vada nitě - osnova.

4.2 Detekce vad v útkovém směru

Jak už bylo zmíněno výše, informace o hlavních směrech v původním obraze je koncentrována v obraze spektra ve směrech s vysokými hodnotami frekvenčních komponent. Odstranění významných směrů (v našem případě např. soustavy nití) je možné nastavením frekvenčních hodnot ve spektru odpovídající dané soustavě nití na nulu. Obnovený obraz je pak získán použitím inverzní Fourierovy transformace. V obnoveném obraze zůstane informace jen o jedné soustavě nití, jak je vidět na obrázcích 4.5(e),(f). Ze získaného profilu jedné soustavy nití a nalezením nejvýznamnější frekvence lze automaticky určit odhad dostavy tkaniny. Profil úrovní šedi si můžeme představit jako periodickou časovou řadu, kde vysoké hodnoty úrovní šedi představují nitě a nízké hodnoty úrovní šedi mezery mezi nitěmi. Základním nástrojem pro popis periodické časové řady je periodogram $I(\omega)$, který pro konečnou posloupnost náhodných veličin y_1, \dots, y_n definujeme jako funkci proměnné ω ve tvaru (viz *Anděl* [41])

$$I(\omega) = \frac{1}{2\pi n} \left| \sum_{t=1}^n y_t e^{-it\omega} \right|^2, \quad -\pi \leq \omega \leq \pi. \quad (4.3)$$

Periodogram slouží jako nástroj pro nalezení významných periodických složek v dané časové řadě. Objektivní metodou, která umožňuje statisticky rozhodnout, jaké hodnoty periodogramu můžeme opravdu považovat za významně velké ve srovnání s jeho ostatními hodnotami je Fischerův test periodicity (viz např. *Anděl* [41], *Cipra* [42]). Nulová hypotéza ve Fischerově testu má tvar $H_0 : y_t = \varepsilon_t$, tj. předpokládá se, že řada neobsahuje žádnou periodickou složku a je přímo rovna bílému šumu ε_t s rozdělením $N(0, \sigma_\varepsilon^2)$. Tato nulová hypotéza je testovaná oproti alternativní hypotéze ve tvaru

$$H_A : y_t = \mu + \sum_{j=1}^p (\alpha_j \cos(\omega_j t) + \beta_j \sin(\omega_j t)) + \varepsilon_t, \quad t = 1, \dots, n, \quad (4.4)$$

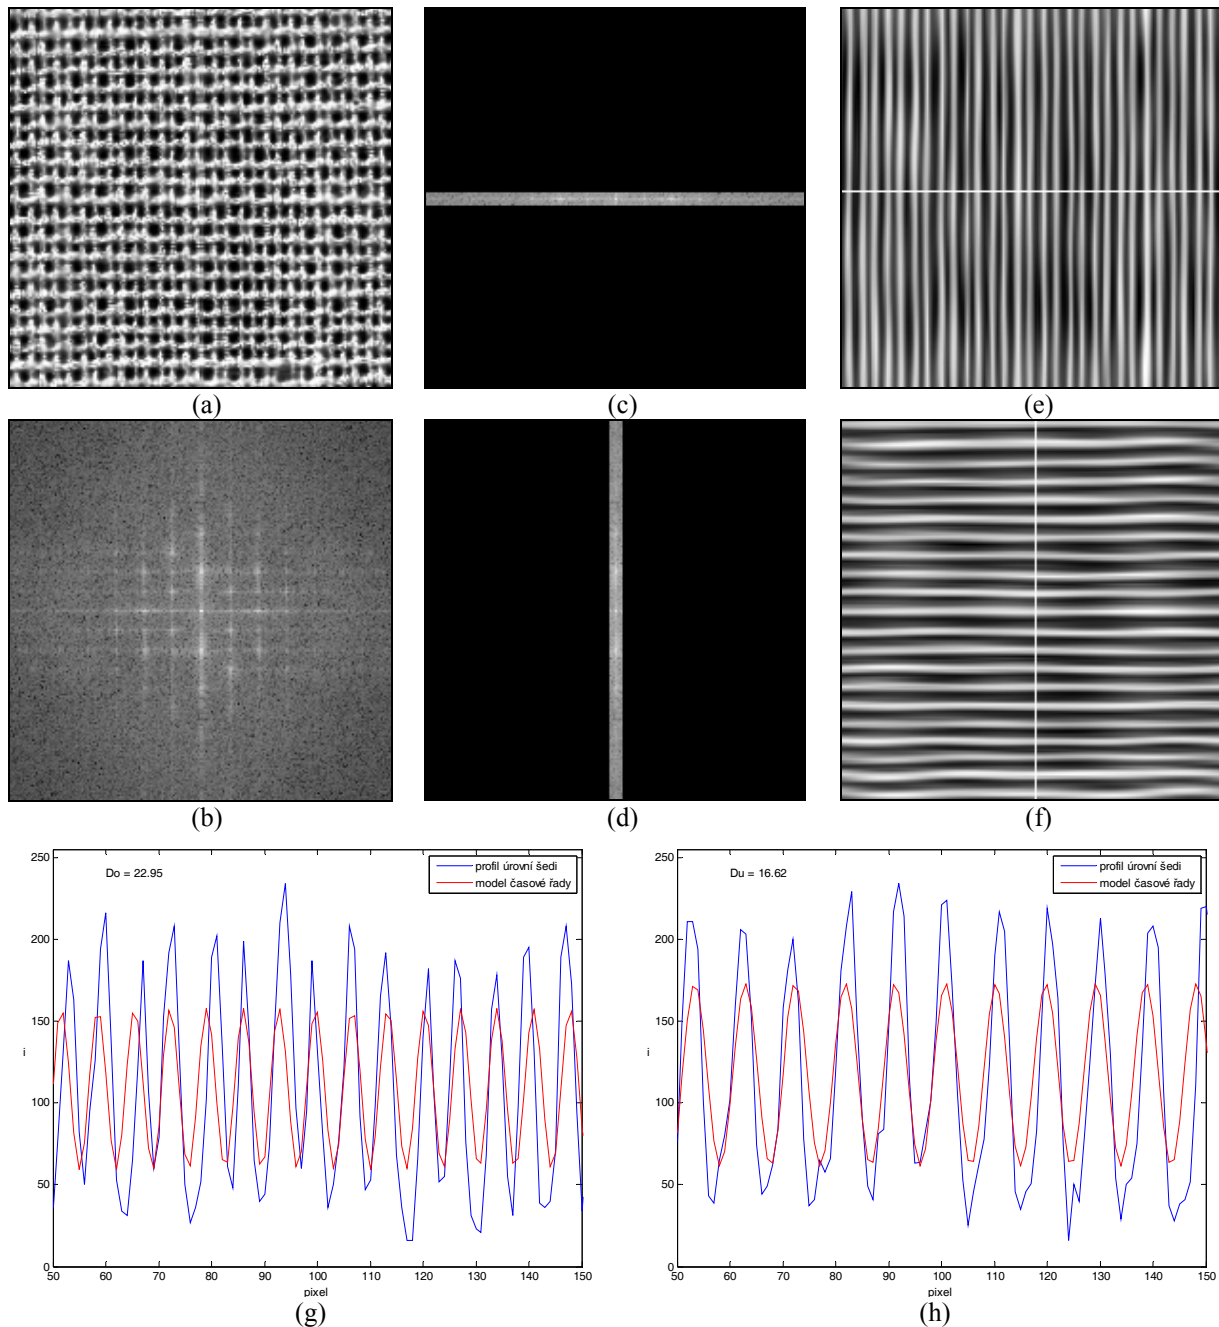
kdy se řada y_t chápe jako směs konečného počtu goniometrických funkcí s různými frekvencemi $\omega_1, \dots, \omega_p$ s úrovní μ a s přidaným bílým šumem ε_t . Testová statistika ve Fischerově testu je založena na hodnotách periodogramu dané řady y_1, \dots, y_n vypočtených pro frekvence ω_j^* . Jestliže platí nulová hypotéza, potom by žádná z těchto hodnot periodogramu neměla být významně větší než zbývající hodnoty. Fischerův test vlastně odpovídá na otázku, jestli některé hodnoty periodogramu můžeme považovat za významně velké, což souvisí s výskytem periodických složek v řadě. Tato metoda nám umožňuje na základě statistických postupů určit v modelu (4.4) významné frekvence ω_j (frekvence ω_j jsou zde typu ω_j^*).

Dostavu tkaniny je možné vyhodnotit na základě nalezení periodicity T (délky periody, po které se pravidelně opakují nitě jedné soustavy) v horizontálním a vertikálním směru obnoveného obrazu tkaniny. Jestliže známe rozlišení R (pixel/palec) při kterém byl získán obraz je možné určit dostavu tkaniny $D_{o,u}$ (počet nití/cm) podle vzorce

$$D_{o,u} = \frac{R/2.54}{T}, \quad (4.5)$$

kde $T = 2\pi/\omega_j^*$ a ω_j^* je první nejvýznamnější frekvence určená z Fischerova testu periodicity.

Příklad na obrázku 4.5(e) zobrazuje obnovený obraz osnovní soustavy nití získaný z obrazu tkaniny v plátňové vazbě z obrázku 4.5(a). Na obrázku 4.5(g) je modrou barvou vyneseny profil úrovní šedi osnovních nití vybraný ve středu obrazu od 50 do 150 pixelu a červenou barvou model časové řady vypočtený ze vztahu (4.4) pro nejvýznamnější frekvenci ω_j^* . S využitím rovnice (4.5) je vypočtená dostava osnovních nití $D_o = 22.95$ nití/cm. Skutečná dostava osnovních nití je 23.0 nití/cm. Dostava útkových nití získaná stejnou technikou je $D_u = 16.62$ nití/cm, skutečná dostava útkových nití je 15.5 nití/cm. Celý proces určování je automatický, kde vstupními parametry jsou vstupní obraz a rozlišení, při kterém byl obraz snímán. Výstupem je hodnota dostavy tkaniny v osnovním a útkovém směru v počtu nití na cm, uživatelské rozhraní bylo vytvořeno v programu MATLAB.



Obrázek 4.5 (a) Obraz plátňové vazby o velikosti 200 x 200 pixelů, (b) výkonové spektrum, (c),(d) výřez (pruh) ze spektra pro parametry $\varphi = 0^\circ$, $\varphi = 90^\circ$, $\Delta w = 7$ pixelů a (e), (f) obnovené obrazy po 2D IDFT, (g),(h) graf profilu úrovní šedi a graf modelu časové řady pro osnovní a útkovou soustavu nití..

Metoda automatického zjišťování dostavy tkaniny může být využita pro detekci vad, zejména pro ty, které jsou určitým způsobem spojené se změnou dostavy tkaniny. Vhodné je použití pro vady ve směru útku, které se rozkládají po celé šířce tkaniny. Myšlenka detekce defektů v útkovém směru je založena na sledování informace o hodnotě dostavy útku ve směru délky tkaniny. Změna hodnoty dostavy oproti očekávané hodnotě indikuje porušení struktury. Ve stejném řádku obrazu tkaniny je náhodně vybráno $n = 5$ oken o velikosti 100×100 pixelů, které představují opakovaná měření stejné veličiny prakticky ve stejném čase. Pak v různých časech můžeme získat několik výběrů V_1, \dots, V_m . Pro každý výběr V_j stejné velikosti n jsou určeny výběrové průměry x_{sj} a směrodatné odchylky s_j . Při předpokladu normality rozdělení $N(d, \sigma^2/n)$ výběrových průměrů x_s a nezávislosti výběrových průměrů je odhadem střední hodnoty d generální průměr definován vztahem (viz *Meloun & Militký* [38])

$$d^* = \frac{1}{m} \sum_{j=1}^m x_{sj} \quad (4.6)$$

a odhadem směrodatné odchylky je

$$\sigma^* = \frac{1}{mC_4} \sum_{j=1}^m s_j \quad (4.7)$$

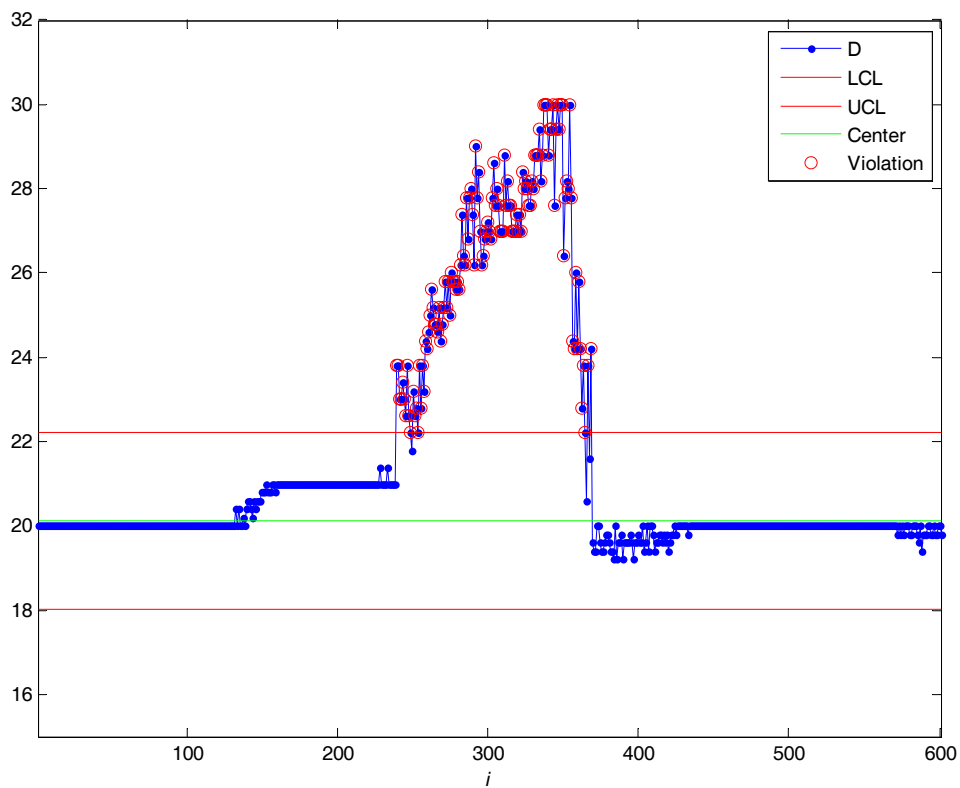
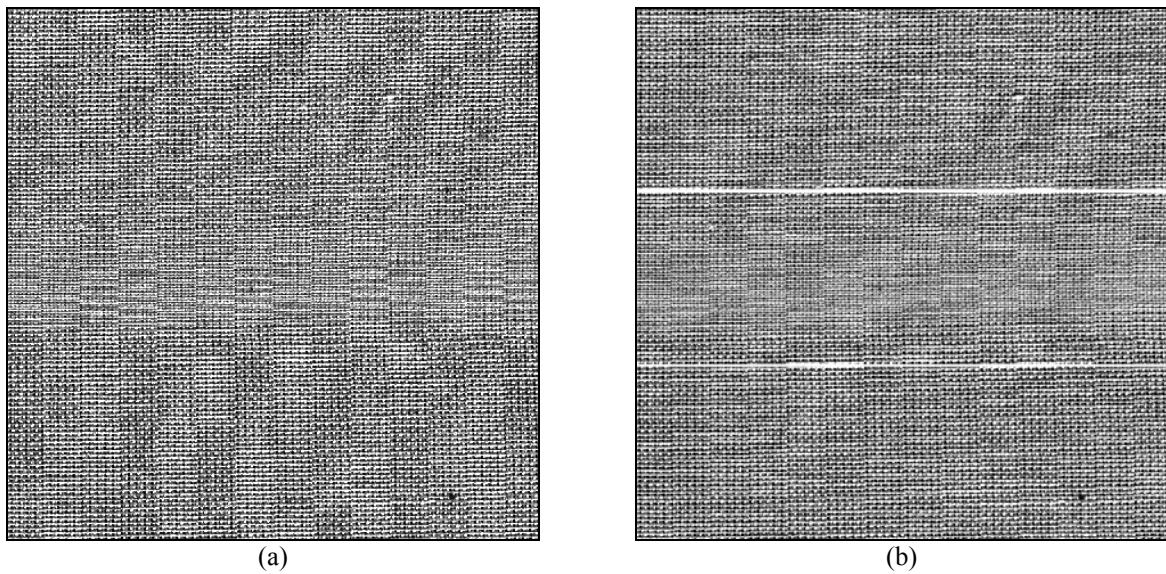
kde $C_4 \approx 1 - 1/(4n - 1)$ je konstanta zajišťující nevychýlenost. Regulační diagramy \bar{x} využívají k posuzování stavu sledovaného procesu (v tomto případě hodnota dostavy) aritmetické průměry x_{sj} . Ke své konstrukci vyžadují znalost parametrů d , σ^2 normálního rozdělení, nebo pouze znalost vhodných odhadů d^* a σ^2 . Regulační diagram \bar{x} má pak centrální linii (*CL, Central Line*) d^* a odhad regulačních mezí můžeme vypočítat podle

$$UCL, LCL = d^* \pm \frac{1.96\sigma^*}{\sqrt{n}} \quad (4.8)$$

kde konstanta 1.96 představuje $100(1 - 0.05/2) = 97.5$ % - ní kvantil normovaného normálního rozdělení $u_{0.975}$, tj. 95 % - ní pravděpodobnost s jakou se veličina vyskytuje v regulačních mezích, tj. proces je v požadovaném stavu (v tomto případě hodnota dostavy). V první fázi byly získané hodnoty dostavy tkaniny na základě spektrálního přístupu pro $n = 5$ náhodně vybraných oken v jednom řádku obrazové matice o velikosti 100×100 pixelů pro $m = 1000$ výběrů z obrazu tkaniny. Veličina d^* stanovená podle vztahu (4.6) vykazovala přibližně normální rozdělení. Na základě vztahů (4.7) a (4.8) byl určen odhad směrodatné odchylky a následně horní a dolní regulační mez na hladině významnosti $\alpha = 0.05$. V další fázi byla provedena detekce defektů v útkovém směru ve tkanině. Algoritmus detekce je založen na systematickém výpočtu dostavy tkaniny po řádcích obrazové matice pro skupinu $n = 5$ náhodně vybraných oken v každém řádku o velikosti 100×100 pixelů. Výběrové průměry pak byly vynášeny do regulačního diagramu. Při překročení regulačních mezí je oblast považována za oblast, která vykazuje poruchu, odchýlení od periodicity struktury tkaniny. Na obrázku 4.6(a) je obraz struktury tkaniny v plátňové vazbě, přibližně ve středu obrazu se objevuje defekt nadměrná dostava ve směru útku, která se projevuje zhuštěním nití v určité oblasti. Pro každý řádek obrazu byla na základě spektrálního přístupu vypočtena dostava tkaniny a vynesena do regulačního diagramu na obrázku 4.6(c). Zelená linie představuje dostavu tkaniny (centrální linii), červené linie jsou horní a dolní regulační mez. Překročení

regulačních mezí, v tomto případě UCL , ukazuje na zhuštění dostavy útkových nití v oblasti přibližně od 260. pixelu do 380. pixelu. Oblast je zobrazena na obrázku 4.6(b).

Stejně jako v předchozí kapitole o detekci vad s využitím charakteristik druhého řádu je obraz tkaniny statický a kontrola probíhá s použitím posuvného okna. V reálném provozu je v pohybu tkanina, která je odtahována, statické by byly snímače obrazu, např. kamery, rovnoměrně rozmístěné po celé šířce tkaniny. Tento přístup je zejména vhodný pro vady v útkovém směru, které jsou určitým způsobem spojeny se změnou dostavy, např. útkové pruhy nebo změna útkové dostavy.



(c)

Obrázek 4.6 (a) Defekt v reálné struktuře (nedostatečná dostava - útek), (b) výsledek realizace algoritmu, (c) regulační diagram pro hodnotu dostavy útku.

4.3. Detekce vad s využitím 2D DFT

Vzhledem k povaze struktury tkaniny je možné vady tkaniny rozdělit na vady v útkovém směru, v osnovním směru a vady nezávislé na směru. To znamená, že změny struktury způsobené vadou by se měly objevit ve směru f_x a f_y ve frekvenčním spektru. Navržená metoda využívá spektrum k výpočtu dvou funkcí, profilu $|F(f_x, 0)|$ ve směru f_x a profilu $|F(0, f_y)|$ ve směru f_y . Pro tyto funkce je vypočteno 5 významných charakteristik založených na nejvýznamnější frekvenci na základě studie, kterou provedl *Chan & Pang* v práci [18]. Jedná se o tyto charakteristiky

$$\begin{aligned}
 v_1 &= |F(0,0)|, \\
 v_2 &= 100 \frac{|F(f_{x1}, 0)|}{|F(0,0)|}, & v_3 &= 100 \frac{|F(0, f_{y1})|}{|F(0,0)|}, \\
 v_4 &= 100 \left(\frac{\sum_{f_{xi}=0}^{f_{x1}} |F(f_{xi}, 0)|}{|F(0,0)|} \right), & v_5 &= 100 \left(\frac{\sum_{f_{yi}=0}^{f_{y1}} |F(0, f_{yi})|}{|F(0,0)|} \right),
 \end{aligned} \tag{4.9}$$

kde f_{x1} , f_{y1} korespondují s nejvýznamnější frekvencí. První charakteristika v_1 vyjadřuje průměrnou světelnou intenzitu obrazu. Charakteristiky v_2 , v_4 obsahují informaci o osnovní soustavě nití a charakteristiky v_3 , v_5 o útkové soustavě nití.

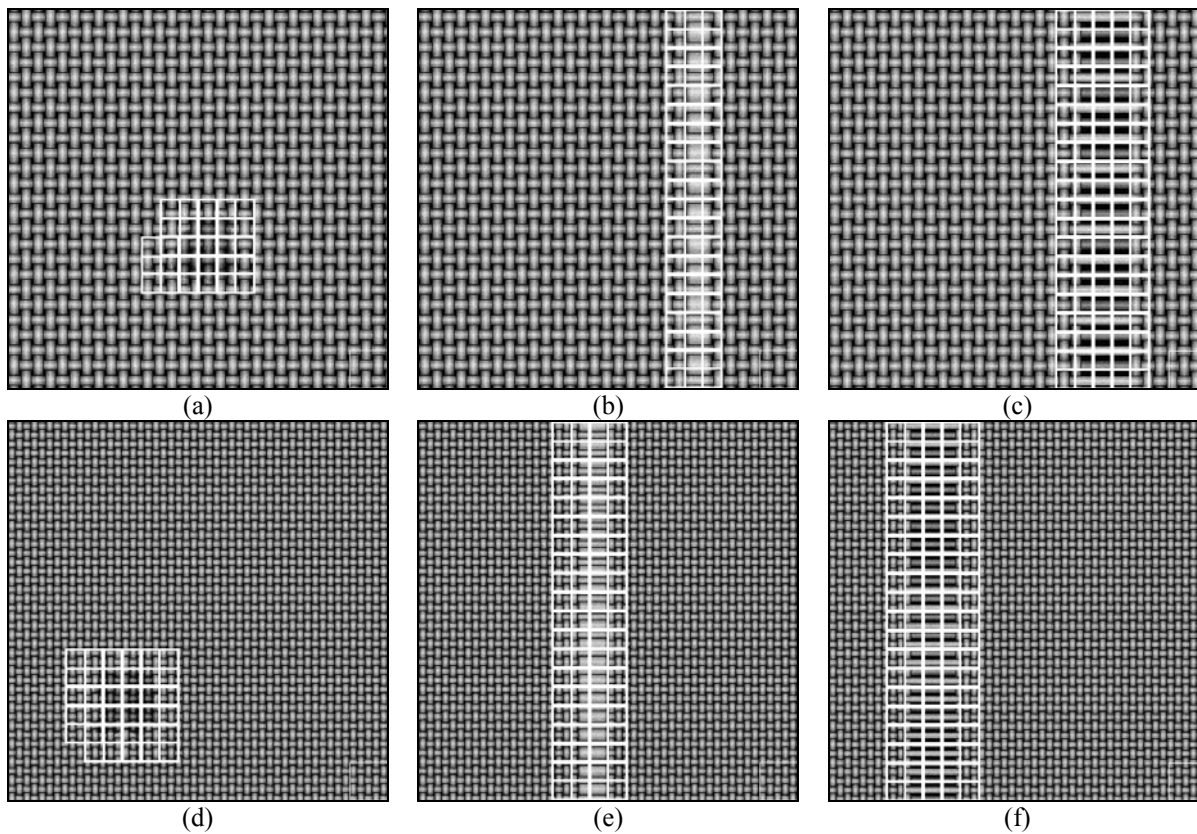
Myšlenka detekce je opět založena na zjištění optimálních charakteristik, které korespondují s určitou neporušenou strukturou („třénovací“ data). Hotellingove regulační diagramy jsou použité jako nástroj pro stanovení regulačních mezí a následnou automatickou kontrolu defektů.

V první fázi bylo vypočteno $p = 5$ charakteristik podle vztahů (4.11) pro 1000 náhodně umístěných oken o velikosti 50 x 50 pixelů v simulovaném obraze neporušené struktury tkaniny. Z dat byla vypočtena horní regulační mez UCL na hladině významnosti $\alpha = 0.001$. Detekce defektních oblastí byla pak realizována stejně jako v případě statistického přístupu. Posuvné okno o velikosti 50 x 50 pixelů se systematicky po kroku 25 pixelů posouvalo po celé ploše obrazu o velikosti 500 x 500 pixelů. Pro každé okno byla napočtena i -tá testová statistika podle vztahu (4.2) a vynesena proti horní regulační mezi UCL . Jestliže i -té pozorování bylo mimo mez, okno bylo považováno za okno obsahující defekt.

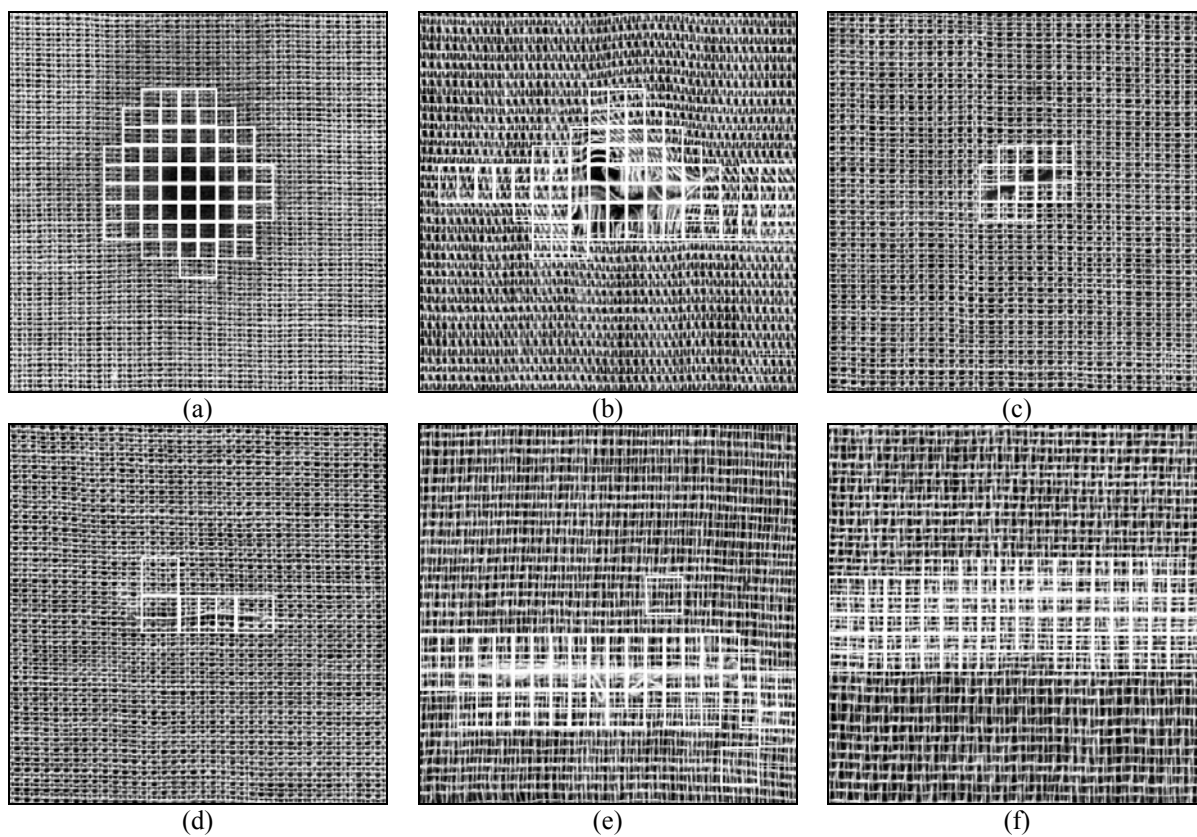
Obrázky 4.7(a)-(c) zobrazují výsledek použití algoritmu detekce na simulovaných strukturách obsahujících běžné defekty, obrázky 4.7(d)-(f) ukazují výsledek algoritmu na stejných typech vad, ale s jinými parametry struktury tkaniny.

Stejná technika byla využita při detekci vad v reálných strukturách. Výsledky detekce pro některé typy vad jsou zobrazeny na obrázcích 4.8(a)-(f).

Ze získaných výsledků lze konstatovat, že algoritmus detekce, který používá spektrální charakteristiky založené na nejvýznamnějších frekvencích získaných z Fourierova frekvenčního spektra ve dvou směrech je vhodný pro detekci vad v simulovaných i v reálných strukturách. Užitím této metody můžeme detekovat vady spojené se změnou dostavy tkaniny a kontrastní nesměrové vady. V porovnání se statistickým přístupem se zlepšila detekce u typů vad, které nezpůsobují příliš velkou změnu struktury, jako například vady dvoják, smyčka, flotáž. Na obrázcích 4.9(b)-(f) jsou zobrazeny výsledky detekce pro různou velikost prohlížečského okna. Je proto potřeba nalézt vhodnou optimalizační metodu, která by pomohla optimalizovat vhodnou velikost prohlížečského okna vzhledem k typu struktury tkaniny.

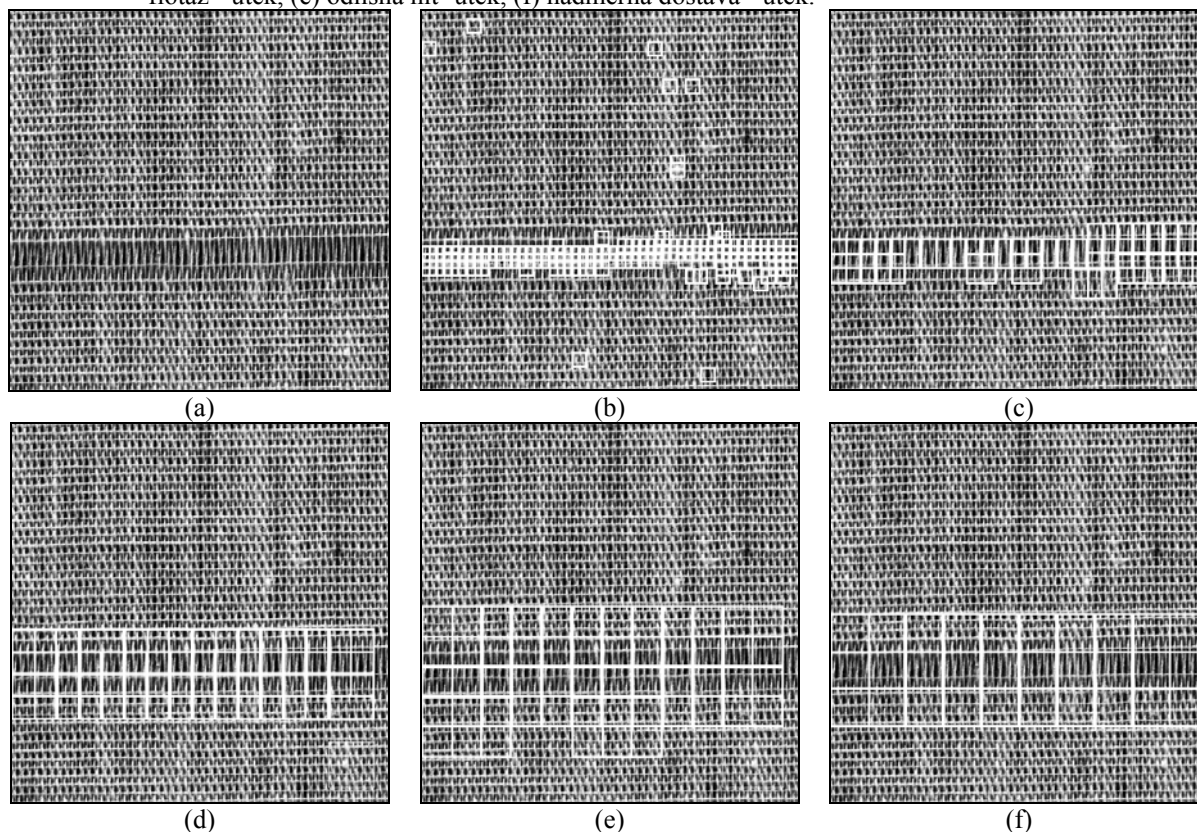


Obrázek 4.7 Výsledek použití algoritmu na simulovaných vadách: (a),(d) skvrna, (b),(e) tlustá nit - osnova, (c),(d) přetržené osnovní nitě.



Obrázek 4.8 Výsledek použití algoritmu v reálných strukturách: (a) skvrna, (b) díra, (c) zatkaný předmět, (d)

flotáž - útek, (e) odlišná nit- útek, (f) nadměrná dostava - útek.



Obrázek 4.9 Výsledek použití algoritmu v reálné struktuře s vadou nedostatečná dostava - útek při použití velikosti prohlížečního okna: (b) 20, (c) 40, (d) 60, (e) 80, (f) 100 pixelů.

5. Zhodnocení výsledků a nových poznatků

V předložené disertační práci byl studován statistický a spektrální přístup pro detekci běžných defektů vyskytujících se ve tkaných textiliích jako součást kontroly kvality v textilním průmyslu. Statistický přístup byl založen na texturních charakteristikách druhého řádu získaných z matic plošných šedotónových závislostí. Pomocí metody CART byly stanoveny texturní charakteristiky s největší diskriminační silou, které pak byly použité pro detekci vad v texturních obrazech tkanin. Dále byl studován spektrální přístup, který vycházel z Fourierova frekvenčního spektra textury. Na základě dvou funkcí získaných ze spektra bylo vypočteno pět charakteristik, které souvisejí s nejdůležitějšími frekvencemi.

Algoritmus detekce byl založen na systematickém prohlížení statického obrazu tkaniny posuvným oknem. Ve skutečném provozu je tkanina odtahovaná na válec rovnoměrnou rychlostí. V případě online kontroly by byly statické snímače obrazu rozmístěné rovnoměrně nad tkaninou po celé její šířce. K automatické detekci defektních oblastí byla použita technika současného monitorování více texturních charakteristik založená na vícerozměrných regulačních diagramech. Automatický systém vypočítá sadu optimálních charakteristik, které odpovídají neporušené části určité struktury tkaniny („trénovací“ data). Z dat jsou, jako obvykle, stanoveny regulační meze. Algoritmus automatické detekce je pak následně aplikován na kontrolu tkaniny, která obsahuje defekty nebo porušení struktury. Z tohoto úhlu pohledu nezáleží na parametrech struktury tkaniny (např. průměr přízí, dostava, vazba). Na druhé straně důležitým parametrem pro detekci je velikost prohlížečního okna. Automatická detekce byla testována a aplikována na běžné typy vad a to jak v simulovaných strukturách tak i v strukturách reálných.

V práci bylo ověřeno, že algoritmus detekce založený na statistických charakteristikách druhého řádu je použitelný pro detekci vad ve tkaninách. Tímto postupem můžeme efektivně detekovat směrové, ale taky nesměrové typy vad. Algoritmus není vhodný pro vady, které nezpůsobují příliš velké změny struktury, jako např. vada dvoják, smyčka nebo flotáž. Automatická detekce založená na spektrálních charakteristikách získaných z Fourierova frekvenčního spektra vykazuje větší přesnost detekce vad. Užitím této metody můžeme detekovat vady spojené se změnou dostavy tkaniny a kontrastní nesměrové vady. V porovnání se statistickým přístupem se zlepšila detekce u typů vad, které nezpůsobují příliš velkou změnu struktury.

Rekonstrukce obrazu využívající dvojrozměrnou Fourierovou transformaci byla aplikována na úlohu automatického určení dostavy tkaniny. Celý proces lze označit za automatický. Vstupními parametry jsou vstupní obraz a rozlišení, při kterém byl obraz snímán. Výstupním parametrem je pak dostava tkaniny. Metoda automatického zjišťování dostavy tkaniny může být také využita pro detekci vad, které jsou určitým způsobem spojené se změnou dostavy. Vhodné je použití pro vady ve směru útku, které se rozkládají po celé šířce tkaniny. Myšlenka detekce defektů v útkovém směru je založena na sledování informace o hodnotě dostavy útku ve směru délky tkaniny. Změna hodnoty dostavy oproti očekávané hodnotě indikuje porušení struktury.

Fourierova transformace se rovněž ukázala jako vhodná pro stanovení strukturní anizotropie nebo směrové orientace vlákných a jiných objektových systémů. Metoda by mohla být využita pro zkoumání směrových vlastností a homogenity vlákných systémů. Vizualizace úlohy byla provedena ve formě polárního diagramu jako odhadu směrové růžice. Výhodou metody je její rychlost. Výsledek je k dispozici ihned po načtení obrázku a aplikaci algoritmu. Bylo provedeno srovnání výsledků s metodou odhadu směrové růžice s využitím grafické konstrukce Steinerova kompaktu. Metoda je použitelná taky pro detekci vad ve tkaninách.

Pro získání lepších výsledků při detekci a klasifikaci vad v tkaných textiliích se ukazuje, že bude potřebné kombinovat různé texturní přístupy a různé velikosti plovoucích oken. První práce tohoto typu se objevily teprve nedávno. Příkladem může být práce *Garcia & Puig* [50]. Rovněž možnost modelování textury plošné textilie pomocí 2D Woldovy dekompozice homogenního náhodného pole se zdá být využitelná pro detekci vad v pravidelné struktuře (viz např. *Liu* [51], *Liu & Pickard* [52]). Na základě Woldovy dekompozice může být obraz textury rozložen na deterministickou složku obrazu a čistě indeterministickou složku obrazu. Deterministická složka obrazu obsahuje hlavní strukturní rysy textury, kdežto indeterministická složka má náhodou povahu. Cílem je nalézt vhodný algoritmus pro určení jednotlivých složek tohoto rozkladu a použít tento postup pro účinnou detekci defektů ve tkanině.

6. Práce autora se vztahem ke studované problematice

- [1] TUNÁK, M., LINKA, A. Applying Spectral Analysis to Automatic Inspection of Weaving Density. *Proceedings of 11th International Conference on Structure and Structural Mechanics of Textiles (STRUTEX 2004)*. Liberec, 6.12.-7.12. 2004, pp. 133-140, ISBN 80-7083-891-4.
- [2] TUNÁK, M., LINKA, A. Fourier Analysis of Woven Composite Structures. *12th International Conference on Composites or Nano Engineering (ICCE 12), Conference Proceedings on DVD*. Tenerife, Canary Islands, Spain, August 1.-6. 2005.
- [3] TUNÁK, M., LINKA, A. Planar anisotropy of fiber system by using 2D Fourier transform. *Proceedings of 12th International Conference on Structure and Structural Mechanics of Textiles (STRUTEX 2005)*, Liberec, 28.11.-29.11. 2005, pp. 121-127, ISBN 80-7372-002-7.

- [4] TUNÁK M., LINKA, A., VOLF P. Stochastic Simulation of Deformation in Fabrics as Composite Reinforcement. *12th European Conference on Composite Materials (ECCM 12), Conference Proceedings on DVD*. Biarritz, France, 29.8.-1.9. 2006, 8 pages.
- [5] TUNÁK M., LINKA, A. Simulation and recognition of common fabric defects. *Proceedings of 13th International Conference on Structure and Structural Mechanics of Textiles (STRUTEX 2006)*. Liberec, 27.11.-29.11. 2006, pp. 363-370, ISBN 80-7372-135-X.
- [6] KRUPICOVÁ, G., TUNÁK M. Practical approach to the yarn hairiness determination. *2nd International Conference of Applied Research on Textile (CIRAT-2), Conference proceedings on CD*. Monastyr, Tunisia, December 2006, 4 pages.
- [7] TUNÁK, M., LINKA, A., KALABISHKA, Y. Directional defects in fabrics. *6th International Conference Textile Science (TEXSCI 07), Conference Proceedings on CD*. Liberec, 05.06.-07.06. 2007, 7 pages, ISBN 978-80-7372-207-4.
- [8] LINKA, A., TUNÁK, M. Quality control of fabric based on Fourier analysis. *Mathematical Methods in Reliability (MMR07). Conference Proceedings on CD*. Glasgow, UK, 1. - 4. July 2007. 9 pages.
- [9] TUNÁK, M., LINKA, A. Methods for Recognition of Woven Structure Defects. *15th International Conference on Composites or Nano Engineering (ICCE 15), Conference Proceedings on DVD*. Haikou, China, July 15.-21. 2007.
- [10] TUNÁK, M., LINKA, A. Analysis of Planar Anisotropy of Fibre Systems by using 2D Fourier Transform. *5th Central European Conference "Fibre-grade polymers, chemical fibres and special textiles" (CEC'2007), Conference Proceedings*, Cracow – Bielsko-Biala, Poland, 5.-8 September 2007.
- [11] TUNÁK, M., LINKA, A. Applying Spectral Analysis to Automatic Inspection of Weaving Density. *Sborník z 15. semináře „Moderní matematické metody v inženýrství (3mi)“*. Dolní Lomná, 29.5.-31.5. 2006, JČMF, VŠB-TU Ostrava, pp. 205-211, ISBN 80-248-1224-X.
- [12] TUNÁK M., LINKA, A. Planar Anisotropy of Fibre Systems by Using Matlab Image Processing Toolbox. *Technical Computing Prague 2006, Conference proceedings on CD*. Kongresové centrum ČVUT, Praha, 26.10. 2006, 8 pages, ISBN 80-7080-616-8.
- [13] TUNÁK M., LINKA, A. Simulation and recognition of common fabric defects. *REliability, QUality and ESTimation (REQUEST'06), Sborník z konference*. Praha, 30.01.-01.02.2007, pp. 229-238, ISBN 978-80-01-03709-6.
- [14] LINKA, A., TUNÁK, M., VOLF, P. Stochastická simulace postupných deformací tkaniny. *REliability, QUality and ESTimation (REQUEST'06), Sborník z konference*. Praha, 30.01.-01.02.2007, pp. 239-249, ISBN 978-80-01-03709-6.
- [15] LINKA, A., TUNÁK, M. Dostava tkaniny. *Sborník přednášek ze semináře „Zajištění kvality analytických výsledků“ (2 Theta)*. Komorní Lhotka, 26.-28.01.2007, pp. 172-178, ISBN 978-80-86380-37-7.
- [16] TUNÁK M., LINKA, A., VOLF P. Stochastic Simulation of Deformation in Fabrics as Composite Reinforcement. Submitted to *Composites Science and Technology*, 2007, ISSN 0266-3538.
- [17] TUNÁK, M., LINKA, A. Directional defects in fabrics. Accepted for publication in the *Research Journal of Textiles and Apparel*, 2007. ASIN B0002353NO.
- [18] TUNÁK, M., LINKA, A. Analysis of Planar Anisotropy of Fibre Systems by using 2D Fourier Transform. *Fibres & Textiles in Eastern Europe*, 2007, Vol. 15, No. 5-6 (64-65), ISSN 1230-3666.

7. Literatura

- [1] HARALICK R.M., SHANMUGAM K., DINSTEN I. Textural Features for Image Classification. *IEEE Trans. on Systems, Man, and Cybernetics* **3**, No. 6: 610-621. 1973.
- [2] CARSTENSEN J.M. *Description and Simulation of Visual Texture*. Ph.D. Thesis, No. 59, IMSOR, Technical University of Denmark, 1992.
- [3] LIN J.J. Applying a Co-occurrence Matrix to Automatic Inspection of Weaving Density for Woven Fabrics. *Textile Res. J.* **72**(6), 486-490 (2002).
- [4] KUO C.F.J., SU, T.L. Gray Relational Analysis for Recognizing Fabric Defects. *Textile Res. J.* **73**(5), 461-465 (2003).
- [5] BODNAROVA A., BENNAMOUN M., KUBIK K.K. Suitability Analysis of Techniques for Flaw Detection in Textiles using Texture Analysis. *Pattern Analysis & Applications* **3** (2000), 254-266.
- [6] LINKA A., VOLF P. Statistické metody pro hodnocení homogenity textilních materiálů. *ROBUST'2000, JČMF*, 2001, 164-175.
- [7] ANAGNOSTOPOULOS C. ET AL. A computer vision approach for textile quality control. *J. Visual. Comput. Animat.* 2001; **12**: 31-44.
- [8] ANAGNOSTOPOULOS C. ET AL. Sliding Windows: A Software Method Suitable for Real-Time Inspection of Textile Surface. *Textile Res. J.* **74**(7), 646-651 (2004).
- [9] WOOD J. E. Applying Fourier and Associated Transform to Pattern Characterization in Textiles. *Textile Res. J.* **60**, 212-220 (1990).
- [10] RAVANDI S.A.H., TORIUMI K. Fourier Transform Analysis o Plain Weave Fabric Appearance. *Textile Res. J.* **65**(11), 676-683 (1995).
- [11] JASPER W. J., POTLAPALLI H. Image Analysis of Mispicks in Woven Fabric. *Textile Res. J.* **65**(11), 683-692 (1995).
- [12] XU B. Identifying Fabric Structures with Fast Fourier Transform Techniques. *Textile Res. J.* **66**(8), 496-506 (1996).
- [13] KANG T.J., KIM C.H., OH K.W. Automatic Recognition of Fabric Weave Patterns by Digital Image Analysis. *Textile Res. J.* **69**(2), 77-83 (1999).
- [14] CHIU S.H., CHOU S., LIAW J.J., WEN C.J. Textural Defect Segmentation Using a Fourier-Domain Maximum Likelihood Estimation Method. *Textile Res. J.* **72**(3), 253-258 (2002).
- [15] SHADY E. ET AL. Detection and Classification of Defects in Knitted Fabric Structures. *Textile Res. J.* **76**(4), 295-300 (2006).
- [16] TSAI D.M., HUANG T.Y. Automated Surface Inspection For Statistical Textures. *Image and Vision Computing* **21** (2003) 307-323.
- [17] TSAI D.M., HUANG T.Y. Automated Surface Inspection For Directional Textures. *Image and Vision Computing* **18** (1999) 49-62.
- [18] CHAN C., PANG G.K.H. Fabric Defect Detection by Fourier Analysis. *IEEE Trans. on Industry Applications*, Vol. **36**, No. 5, 2000.
- [19] ESCOFET J., MILLÁN M.S. RALLÓ M. Modeling of woven fabric structures based on Fourier image analysis. *Applied Optics*, Vol. **40**, No. 34, 2001.
- [20] MATLAB. *Creating Graphical User Interfaces*. 2002 The MathWorks, Inc.
- [21] GONZALES, R.C., WOOD, R.E. *Digital Image Processing*. 2nd ed., Prentice-Hall, 2002.
- [22] The American Heritage® Dictionary of the English Language, Fourth Edition. 2000. Houghton Mifflin Company. Dostupné na internetu <http://www.bartleby.com/61/>.
- [23] The Free On-line Dictionary of Computing, © 1993-2006 Denis Howe. Dostupné na internetu <http://foldoc.org/>.
- [24] PETROU M., SEVILLA G.P. *Image Processing, Dealing with Texture*. Wiley & Sons Ltd., 2006.

- [25] Brodatz textures. Dostupné na internetu <http://sipi.usc.edu/database/>
- [26] Online Textile Dictionary. Dostupné na internetu <http://www.resil.com/otd.htm/>
- [27] Institut für Textilmaschinenbau und Textilindustrie der Eidgenössischen Technischen Hochschule. *Catalogue of types of fabric defects in grey goods*. 3rd ed. ITS Publishing, Schlieren/Switzerland, 1996.
- [28] ČSN 80 0016. *Názvy a definice vzhledových vad*, 1987.
- [29] ČSN 80 0025. *Názvosloví vad tkanin*, 1975.
- [30] MARTINEZ W.L., MARTINEZ A.R. *Computational Statistic Handbook with Matlab*. Chapman & Hall/CRC. New York. 2002.
- [31] ZAMBA K.D., HAWKINS D.M. A Multivariate Change-Point Model for Statistical Process Control. *Technometrics*; Nov. 2006; Vol. **48**; No. 4, 539-549.
- [32] BERSIMIS S., PSARAKIS S., PANARETOS J. Multivariate Statistical Process Control Charts: An Overview. *Quality and Reliability Engineering International*. Published online in Wiley InterScience (www.interscience.wiley.com). 2006.
- [33] MASON R.L., CHOU Y.M., YOUNG J.C. Effective Sample Sizes for T^2 Control Charts. *Handbook of Statistics*, Vol. **22**, 2003 Elsevier Science B.V., 595-607.
- [34] LIN H. D. Automated visual inspection of ripple defects using wavelet characteristic based multivariate statistical approach. *Image Vis. Comput.* (2007). Article in press.
- [35] MELOUN M., MILITKÝ J. *Statistické zpracování experimentálních dat*. East Publishing, Praha. 1998.
- [36] SEBER G.A.F. *Multivariate Observation*. John Wiley & Sons, Inc. Publication. New York. 1984.
- [37] RENCHER A.C. *Methods of Multivariate Analysis*. John Wiley & Sons, Inc. Publication. New York. 2002.
- [38] MELOUN M., MILITKÝ J. *Kompendium statistického zpracování dat*. Academia. Praha. 2002.
- [39] ANDĚL J. *Matematická statistika*. SNTL/ALFA. Praha. 1978.
- [40] ANDĚL J. *Statistické metody*. Matfyzpress. Praha. 2003.
- [41] ANDĚL J. *Statistická analýza časových řad*. SNTL. Praha. 1976.
- [42] CIPRA T. *Analýza časových řad s aplikacemi v ekonomii*. SNTL. Praha. 1986.
- [43] LUKÁŠ D. *Stereologie textilních materiálů*. Skriptum. 2000 TU Liberec.
- [44] RATAJ J., SAXL I. Analysis of Planar Anisotropy by Means of Steiner Compact: A Simple Graphical Method. *Acta Stereologica*, 1988; 7/2: 107-112.
- [45] MARTINEZ W.L., MARTINEZ A.R. *Computational Statistics Handbook with MATLAB*. Chapman & Hall/CRC. 2002.
- [46] BODNAROVA A., BENNAMOUN M., LATHAM S. Optimal Gabor filters for textile flaw detection. *Pattern Recognition* **35** (2002) 2973-2991.
- [47] KUMAR A., PANG K.H. Defect Detection in Textured Materials Using Gabor Filters. *IEEE Trans. on Industry Applications*, Vol. **38**, No. 2, 2002.
- [48] KARKKÄINEN S., JENSEN E.B. V. Estimation of fiber orientation from digital images. *Image Anal. Sterol.*, 2001; **20**: 199-202.
- [49] KARKKÄINEN S., JENSEN E.B.V, JEULIN D. On the orientation analysis of planar fiber systems from digital images. *Journal of Microscopy*, Vol. 207, Pt 1, 2002, pp. 69-77.
- [50] GARCÍA, M. G., PUIG, D. Supervised texture classification by integration of multiple texture methods and evaluation windows. *Im. and Vision Comp.* **25** (2007) 1091-1106.
- [51] LIU, F. Modeling Spatial and Temporal Textures. Ph.D. Thesis, Massachusetts Institute of Technology, 1997.
- [52] LIU, F., PICARD, R. W. Periodicity, Directionality and Randomness: Wold Features for Image Modeling and Retrieval. *IEEE Trans. on Pattern Analysis and Machine Intelligence*, Vol. **18**, No. 7, July 1996.

8. Souhrn

V předložené disertační práci byl studován statistický a spektrální přístup pro detekci běžných defektů vyskytujících se ve tkaninách. Statistický přístup byl založen na statistických charakteristikách druhého řádu. Pomocí metody CART byly stanoveny texturní charakteristiky s největší diskriminační silou, které pak byly využity pro detekci defektů v texturních obrazech tkanin. Dále byl studován spektrální přístup, který vycházel z Fourierova frekvenčního spektra textury. Na základě dvou funkcí získaných ze spektra bylo vypočteno 5 charakteristik souvisejících s nejvýznamnější frekvencí. K automatické detekci defektních oblastí byla použita technika současného monitorování více texturních charakteristik založená na vícerozměrných regulačních diagramech. Rekonstrukce obrazu využívající dvojrozměrnou Fourierovu transformaci byla aplikována na úlohu automatického určení dostavy tkaniny. Fourierova transformace se rovněž ukázala jako vhodná pro stanovení směrové orientace vlákných nebo jiných systémů. Navrhované metody jsou vhodné pro detekci běžných typů defektů, což potvrzují výsledky získané jak na simulovaných strukturách tak na obrazech reálných textilií.

Summary

The thesis deals with statistical and spectral approach for detection of common defects occurring in woven fabric. Statistical approach was based on second-order grey level statistic features. Features with high discriminatory power were determined by means of CART techniques that consecutively were used for defect detection in fabric images. Second approach was derived from the Fourier frequency spectrum. A set of five features based on the first-most significant frequency can be extracted from the two significant spectral diagrams. Multivariate statistical process control via control charting was used as a tool for automatic defect detection. Image restoration using the Fourier transform was applied for the task of automatic assessing of weaving density. The Fourier transform seems to be appropriate for the graphical representation of directional arrangement of fibre or other systems. The results show that the methods of detection of common woven fabric defects are suitable for simulated samples as well as for real samples with different structure.

Резюме

В данной диссертационной работе рассматривается вопрос статистического и спектрального подхода к детектированию стандартных дефектов тканей. Статистический подход основан на статистических характеристиках второй степени. Путём методы CART были установлены текстурные характеристики с максимальной дискриминационной силой, которые вследствие были использованы к детектированию дефектов в текстурных изображениях тканей. Следующий подход основан на методе частотной оптической Фурье-спектроскопии текстур. Исходя из двух функций полученных из спектра, было исчислено 5 характеристик, связанных с наиболее значимой частотой. К автоматическому детектированию дефектных областей была применена техника современного мониторинга большого количества текстурных характеристик, основанная на многомерных регулировочных диаграммах. Восстановление изображения, исходя из двухмерного преобразования Фурье, было применено в автоматическом определении плотности ткани. Одновременно оказалось, что преобразование Фурье является подходящим к определению направления волоконных или иных систем. Результаты подтверждают, что предлагаемые методы являются пригодными к детектированию обычных видов дефектов как в симулированных структурах, так и на изображениях реального текстиля.

Vydala Textilní fakulta, Technické univerzity v Liberci
jako interní publikaci pod pořadovým číslem
DFT/11/2008 v počtu 20 výtisků