

Bibliografische Beschreibung

Rohrmus, Dominik

Adaptive invariant features for texture classification

Dissertation an der Fakultät für Maschinenbau der Technischen Universität Chemnitz, Institut für Werkzeugmaschinen und Produktionsprozesse, Professur Virtuelle Fertigungstechnik, Chemnitz, den 9. Januar 2013

Seitenzahl: 168

Anzahl der Abbildungen: 61

Anzahl der Tabellen: 39

Anzahl der Literaturzitate: 256

Referat

Die Qualität vieler industrieller Produkte wird durch deren Oberfläche bestimmt. Anforderungen der modernen, variantenreichen Serienproduktion an Qualität und Produktivität erfordern zunehmend eine automatisierte und flexible Qualitätskontrolle der Muster von Oberflächen, genannt Texturen. In dieser Arbeit wird eine Methode zur Extraktion und Klassifikation von invarianten Texturmerkmalen aus Grauwertkamerabildern entwickelt, welche rotatorische und translatorische Lageunabhängigkeit der Produkte in der Bildebene ermöglicht. Die Texturanpassungsfähigkeit der aus der Methode resultierenden Prüftechnologie erhöht die Variantenflexibilität, gewährleistet Ergebnisreproduzierbarkeit und birgt ein großes betriebswirtschaftliches Potenzial durch eine breite Anwendbarkeit. Diese Effekte werden mittels Optimierung der Merkmalsparameter während einer Trainingsphase erzielt. Die lagerobuste Texturanalyse wird durch die invariante Integration in kleinen Bildregionen über die Rotationsgruppe und das anschließende Eintragen aller Rotationsmerkmalsergebnisse in ein Histogramm pro Region erreicht. Dazu werden drei neue Klassen von Integrationskernen mit freien Parametern eingeführt. Diese Kerne erfassen die Textureigenschaften. Zusätzlich werden neue Kerne entwickelt, welche die Anisotropie der Textur einbeziehen. Diese fangen Orientierungen und die Periodizität der Struktur in kleinen Bildausschnitten ein. Die freien Kern- und Anisotropieparameter werden im Sinne der maximalen Texturunterscheidungsfähigkeit mit Hilfe des Fisher-Kriteriums während einer überwachten Trainingsphase optimiert, welche auf gekennzeichneten Bildern beruht. Die durchgeführten Experimente zeigen verbesserte Klassifikationsgenauigkeit gegenüber den klassischen isotropen, monomialen Merkmalskernen sowohl für die Texturklassifikation mit den Brodatz, MeasTex und VisTex Datensätzen, als auch für die Defektklassifikation mit dem TILDA Textildatensatz. Es wurden starke Verbindungen zwischen den Merkmalskernen und den Anisotropieeinstellungen im Bezug auf verschiedene Arten von Texturen, der Texturunterscheidungsfähigkeit und der Klassifikationsleistung gefunden und diskutiert.

Schlagworte

Texturklassifikation, Texturdefekterkennung, anisotrope Texturanalyse, invariante adaptive Texturmerkmale, anisotrope Texturmerkmale, Merkmalskerne, Fisher–Kriterium Merkmalsdiskriminierung, Merkmalsoptimierung

English version

Abstract

The quality of many industrial products is defined by their surfaces. Requirements on the quality as well as productivity of modern series production facing a high degree of product variants increasingly ask for automated and flexible quality inspection solutions for the patterns of surfaces, called textures. In this work a method for the extraction and classification of invariant texture features is developed, which allows for rotation and translation invariant positioning of the products in the camera plane. The texture adaptability of the inspection technology resulting from this method increases the product variants flexibility, ensures the results reproducibility and thus, is of great economic relevance due to the broad applicability. These effects are realized by the optimization of the feature parameters during a training phase. The position-robust texture analysis is accomplished by the invariant integration in small image regions over the rotation group and the insertion of the resulting rotation features in one histogram per region. Therefore, three novel classes of integration kernels with free parameters are introduced. The kernels capture the texture characteristics. Additionally, novel kernels are developed that acquire the anisotropy of the texture. They capture the orientations and the periodicity of the underlying structures in the image region. The free kernel and anisotropy parameters are optimized with respect to maximum texture discrimination using the Fisher criterion during a supervised training phase, which is based on marked and labeled image samples. The conducted experiments show improved classification accuracy compared to the classical isotropic monomial feature kernels for texture classification with the Brodatz, MeasTex, and VisTex data sets as well as defect classification with the TILDA textile data set. Strong relationships of the feature kernels and the anisotropy settings to certain types of textures, to the texture discrimination, and to the texture classification performance are found and discussed.

Keywords

texture classification, texture defect detection, anisotropy texture analysis, invariant adaptive texture features, anisotropy texture features, feature kernels, Fisher-criterion feature discrimination, feature optimization

Contents

1	Introduction	11
1.1	Problem statement	12
1.2	Contributions of the thesis	12
1.3	Organization of the thesis	13
2	Texture Analysis and Feature Extraction	15
2.1	What is texture ?	15
2.2	Texture categories	17
2.3	Texture analysis	18
2.4	Transformation variant analysis methods	22
2.5	Transformation invariant analysis methods	27
2.6	Method comparisons	33
2.7	Texture adaptive invariant feature methods	34
2.8	Our approach	34
3	Automatic Inspection of Textured Surfaces	35
3.1	Surface inspection requirements and systems	35
3.2	Industrial surface inspection	37
3.3	Industrial textile inspection	38
4	Invariant Feature Theory	41
4.1	Geometric image transformations	41
4.2	Invariant features	43
4.3	Construction of an invariant gray value feature	44
4.4	Euclidean motion invariant feature histogram	45
4.5	Novel feature theory	47
4.5.1	Introduction to feature kernels	48
4.5.2	Feature kernel demands	48
4.6	Feature kernels for gray scale images	48
4.6.1	Monomial	49
4.6.2	Rational function	50
4.6.3	Padé function	51
4.7	Anisotropical texture analysis	52
4.7.1	Relation to pattern perception	53
4.7.2	Analysis concept and kernel for an invariant feature	53
4.7.3	Rational anisotropy kernel	55

4.7.4	Application of the analysis concept	56
4.8	Regions of interest	57
4.8.1	Shape of a ROI	59
4.8.2	Width of a ROI	59
5	Feature Optimization	61
5.1	Introduction	61
5.2	Discrimination criteria	62
5.3	Fisher linear discriminant	63
5.3.1	Criterion	63
5.3.2	Optimal projection	64
5.3.3	Other Fisher approaches	65
5.3.4	Discussion	65
5.4	Optimization of the feature kernel	65
5.4.1	Downhill simplex optimization	66
6	Classification	69
6.1	Introduction	69
6.2	Overview on supervised classifiers	69
6.2.1	Classification techniques and examples	69
6.2.2	Classifier selection criteria	70
6.3	Selection of the classifier	71
6.4	Neural network classifiers	71
6.4.1	Overview	71
6.4.2	Multilayer perceptron network	72
6.4.3	Network training	73
6.4.4	Network capacity	74
6.4.5	Network generalization	75
6.5	Application of the MLP network	75
6.5.1	MLP architecture	76
6.5.2	Supervised classifier training	76
6.6	Class recognition	76
7	Experiments and Results	79
7.1	Experimental parameters	86
7.2	Experiments on the TILDA data set	89
7.3	Experiments on the Brodatz data set	102
7.4	Experiments on the VisTex data set	108
7.5	Experiments on the MeasTex data set	111
7.6	Summary and Discussion	113
8	Conclusion and Perspectives	119
Bibliography		123
List of Figures		141

List of Tables	143
A Notation and Abbreviations	145
A.1 Notation	145
A.2 Abbreviations	146
B Derivations, Data bases	147
B.1 Padé function coefficients	147
B.2 Biological and anisotropy archetypes	148
B.3 Data bases grouping	149
B.3.1 TILDA image files	149
B.3.2 Brodatz image grouping	150
C Application	151
C.1 Image management	151
C.2 Training	151
C.3 Recognition	155
D Survey on Variant and Invariant Features	159
D.1 Transformation variant feature techniques	160
D.2 Transformation invariant feature techniques	164