

И.А. КОНОНОВ

**Методика автоматизированного
определения типа текстуры
отдельного слоя снежной толщи по
фотографиям участков стенки
снежного шурфа**

УДК 004.93

Лаборатория лавинных и
селевых процессов
сахалинского филиала
ФГБУН
«Дальневосточный
геологический институт»
Дальневосточного
отделения
Российской
академии наук,
г.Южно-Сахалинск

Предлагается методика определения типа текстуры снежного слоя по фотографиям участков стенки снежного шурфа с использованием алгоритмов и методов обработки изображений и распознавания образов. Рассматривается вопрос формирования и редукции признакового пространства с выделением наиболее информативного подмножества признаков для описания типа текстуры на фотографиях.

Введение

Основными управляющими параметрами в системе «снежная толща» считаются такие её характеристики как структура и текстура отдельных слоёв, которые наряду с плотностью слоёв определяют её прочностные характеристики и используются при оценке устойчивости снега на склонах, а также при прогнозе лавинной опасности.

В настоящее время при стратиграфических наблюдениях в снежной толще описание её структуры и текстуры является качественным и представляет собой экспертное заключение. Необходимость непосредственного участия специалиста в оценке устойчивости снежной толщи на склоне затрудняет прогноз лавинной опасности в тех районах, где не осуществляют деятельность снеголавинные организации. Наличие инструмента автоматизированного определения параметров снежной толщи позволило бы решить эту проблему.

В данной работе рассматривается вопрос автоматизированного определения типа текстуры снежной толщи на основе алгоритмов обработки изображений и машинного обучения.

Постановка задачи

Поскольку исходные данные о текстуре отдельных слоёв снежной толщи представляют собой фотографии участков стенки снежного шурфа, логично рассматривать задачу автоматизированного определения текстуры как задачу распознавания образов на изображениях. Т.е., необходимо разработать классификатор, который по предоставленной фотографии участка стенки шурфа определит тип текстуры.

При этом необходимо обеспечить инвариантность распознавания относительно незначительного варьирования масштаба снимков.

Признаковое описание текстуры снежного слоя на фотографии

Основным визуальным признаком текстуры снежного слоя является наличие или отсутствие упорядоченных квазивертикальных образований – волокон из кластеров кристаллов, а также размеры кластеров и порового пространства между ними [1,2]. Отсутствие волокон соответствует монолитной текстуре (рис 1 а), наличие волокон различной степени выраженности – столбчатой и волокнистой текстурам (рис 1 б,в).




Рис. 1 Фотографии участков стенки снежного шурфа: а – монолитная текстура, б – столбчатая, в – волокнистая. На фотографиях выровнено освещение методом MSR и увеличена контрастность для улучшения визуального восприятия

В работе анализ кластеров и порового пространства осуществляется по бинаризованным фотографиям участков стенки снежного шурфа. На фотографиях светлым областям соответствуют кластеры кристаллов, тёмным – поровое пространство между кластерами. При бинаризации фотографий кластерам кристаллов и порам будут соответствовать белые и чёрные регионы соответственно (рис. 2).




Рис. 2. Фотографии снежного слоя до и после бинаризации

Необходимо заметить, что в случае с разномасштабными снимками участков стенки шурфа размеры не могут выступать в качестве признаков. Поэтому в работе используются относительные характеристики размеров ледяных кластеров и порового пространства:

1. Относительная площадь кластеров
2. Число связных компонент
3. Средний относительный периметр связных компонент
4. Стандартное отклонение от среднего относительного периметра
5. Средняя относительная площадь связных компонент
6. Стандартное отклонение от средней относительной площади.

Оценка информативности данных признаков проводилась с помощью трёх алгоритмов бинарной классификации: SVM (машина опорных векторов) [3], GBT (деревья градиентного спуска) [4], RTF (случайный лес деревьев) [5]. Алгоритмы последовательно обучались на трёх подвыборках, содержащих образцы только двух

типов текстуры. Значения ошибок классификации на отложенном контроле для каждой пары классов приведены в таблице 1.

Таблица 1.

Качество обучения по парам типов текстур

Пары классов	SVM	GBT	RTF
Монолитная и столбчатая текстура	12%	6%	8%
Монолитная и волокнистая текстура	2%	1%	1%
Столбчатая и волокнистая текстура	30%	29%	29%

Из таблицы видно, что алгоритмы классификации приобрели хорошую обобщающую способность на тех выборках, в которых присутствуют образцы монолитной текстуры. Качество классификации образцов столбчатой и волокнистой текстуры значительно хуже. Данное обстоятельство приводит к идее построения бинарного классификатора для двух следующих классов: в первый класс попадают все фотографии слоёв с монолитной текстурой, во второй – фотографии со столбчатой и волокнистой текстурой.

Ошибки первого и второго рода на контрольной выборке при бинарной классификации на два указанных класса представлены в таблице 2.

Таблица 2.

Качество бинарной классификации. Первый класс – образцы с монолитной текстурой, второй – столбчатой и волокнистой.

	SVM	GBT	RTF
Ошибка I рода	5%	3%	3%
Ошибка II рода	8%	3%	6%

Для повышения качества распознавания будем вычислять указанные выше признаки как средние значения по нескольким бинаризациям исходной фотографии, варьируя порог в некоторой окрестности ε начального порога T (вычисленного методом Отсу [6,7]), с некоторым шагом t . Поскольку фотографии стенки шурфа могут различаться по качеству и условиям съёмки, можно предположить, что усреднённые оценки окажутся более информативными.

На рисунке 3 изображён график изменения качества классификации в зависимости от значения ε (при $t=0.01$). Из графика видно, что при значениях ε из промежутка $[1, 1.2]$ качество классификации наилучшее.




Рис. 3. Качество классификации в зависимости от значения ε

Вместе с тем качество бинарной классификации фрагментов столбчатой и волокнистой текстур (Рис. 4) нельзя считать удовлетворительным.




Рис. 4. Качество классификации в зависимости от значения ε

При экспериментировании с различными преобразованиями изображений до бинаризации (увеличение контраста и сглаживание фильтрами [7]) удалось получить отдельные признаки, по которым видна тенденция к разделению образцов столбчатой и волокнистой текстуры (таб. 3).

Таблица 3.

Качество классификации после некоторых преобразований фотографий текстуры

Комбинация преобразований	Процент ошибок на контроле		
	SVM	GBT	RTF
Увеличение контрастности через изменение диапазона интенсивностей пикселей по порогам 0.3 и 0.7	20%	16%	15%
Увеличение контрастности через изменение диапазона интенсивностей пикселей по порогам 0.3 и 0.7 с последующей медианной фильтрацией с ядром фильтра размера 7.	17%	14%	15%
Фильтрация усредняющим фильтром с ядром размера 3	24%	19%	23%

Построим признаковое пространство по следующей схеме. Сформируем библиотеку преобразований изображения, включающую два множества: множество **B** алгоритмов увеличения контрастности и множество **C** сглаживающих фильтров (таб. 4). Составим комбинации следующего вида: $B_i(C_j(I))$ и $C_j(B_i(I))$, где I – фотография участка стенки снежного шурфа. Для каждой комбинации найдём порог бинаризации методом Отсу и, варьируя значение порога в окрестности ε с шагом t , вычислим средние значения признаков.

Таблица 4.

Библиотека преобразований изображений

Обозначение	Название преобразования	Параметры преобразования
B1	Изменение диапазона интенсивностей исходного изображения	Значения порогов 0.15 и 0.85
B2	Изменение диапазона интенсивностей исходного изображения	Значения порогов 0.25 и 0.75
B3	Изменение диапазона интенсивностей исходного изображения	Значения порогов 0.35 и 0.65
B4	Эквализация (выравнивание) гистограммы	Равномерный закон распределения гистограммы

B5	Эквализация (выравнивание) гистограммы	Треугольный закон распределения гистограммы
B6	Эквализация (выравнивание) гистограммы	Пилообразный закон распределения гистограммы
B7	Эквализация (выравнивание) гистограммы	Экспоненциальный закон распределения гистограммы
B8	Эквализация (выравнивание) гистограммы	Синусно-экспоненциальный закон распределения гистограммы
B9	Эквализация (выравнивание) гистограммы	Нормальный закон распределения гистограммы
B10	Контрастно-ограниченное адаптивное выравнивание гистограммы	
C1	Медианный фильтр	Размер ядра фильтра: 3
C2	Медианный фильтр	Размер ядра фильтра: 7
C3	Медианный фильтр	Размер ядра фильтра: 13
C4	Усредняющий фильтр	Размер ядра фильтра: 3
C5	Усредняющий фильтр	Размер ядра фильтра: 7
C6	Усредняющий фильтр	Размер ядра фильтра: 13
C7	Фильтр Гаусса	Размер ядра фильтра: 3, $\sigma=0.3$
C8	Фильтр Гаусса	Размер ядра фильтра: 7, $\sigma=0.3$
C9	Фильтр Гаусса	Размер ядра фильтра: 13, $\sigma=0.3$
C10	Фильтр Гаусса	Размер ядра фильтра: 3, $\sigma=0.5$
C11	Фильтр Гаусса	Размер ядра фильтра: 7, $\sigma=0.5$
C12	Фильтр Гаусса	Размер ядра фильтра: 13, $\sigma=0.5$

Размерность построенного таким образом признакового пространства 1440, что не значительно меньше размера всей выборки образцов столбчатой и волокнистой текстур. Кроме того, вычисление всех признаков даже для одной фотографии участка стенки снежного шурфа занимает немало времени. Этот недостаток может оказаться критичным при разработке системы экспресс-анализа состояния снежной толщи.

Редукция признакового пространства

Для выделения подмножества наиболее информативных признаков воспользуемся методом случайного поиска с адаптацией (СПА)[8]. Заметим, что сложность полного перебора всех подмножеств признакового пространства имеет оценку 2^{1440} , что делает полный перебор невыполнимой задачей. Среди описанных в литературе методов поиска подмножества наиболее информативных признаков выбор метода СПА обусловлен простотой его реализации, небольшим числом параметров, наличием чётких рекомендаций к выбору параметров и хорошей сходимостью.

Критерий Q информативности набора признаков на каждой итерации алгоритма СПА определим следующим образом. Пусть F – всё множество признаков, $f \subseteq F$ – некоторое подмножество признаков, K_1, K_2, K_3 – бинарные классификаторы на основе алгоритмов SVM, GBT, RTF, $Q(K_i, f)$ – средняя ошибка на скользящем контроле классификатора K_i на множестве признаков f . Тогда $Q(f) = \max_{i=1..3} Q(K_i, f)$. Т.е., на каждой итерации алгоритма СПА для каждого множества f будем обучать классификаторы K_i с применением метода скользящего контроля, и выбирать классификатор с наибольшей ошибкой на контроле.

Алгоритм на псевдокоде

Ввод: множество F , выборка, критерий Q , параметр d

j_0 – минимальное число признаков в наборе

T – число итераций

r – число генерируемых выборов на каждой итерации

h – скорость адаптации

1: установить равные вероятности включения признаков:

$p_1 = p_2 = \dots = p_n := 1/n$;

2: для всех $j = j_0, \dots, n$, где j – сложность наборов:

3: для всех $t = 1, \dots, T$, где t – номер итерации:

4: сгенерировать r наборов признаков согласно распределению $\{p_1, \dots, p_n\}$: $R_{jt} := \{f_{jt}^1, \dots, f_{jt}^r\}$, $|f_{jt}^1| = \dots = |f_{jt}^r| = j$

5: $f_{jt}^{\min} := \arg \min_{f \in R_{jt}} Q(f)$; – лучший из наборов

6: $f_{jt}^{\max} := \arg \max_{f \in R_{jt}} Q(f)$; – лучший из наборов

- 7: $H:=0$; – суммарное наказание худших признаков;
- 8: все признаки $f_s \in f_{jt}^{\max}$ наказать уменьшением вероятности p_s : $\Delta p_s := \min\{p_s, h\}$; $p_s := p_s - \Delta p_s$; $H := H + \Delta p_s$;
- 9: все признаки $f_s \in f_{jt}^{\min}$ поощрить увеличением вероятности p_s : $p_s := p_s + H/j$;
- 10: найти лучший набор сложности j : $f_j := \arg \max_{t=1..T} Q(f_{jt}^{\min})$;
- 11: запомнить, какую сложность имел самый лучший набор:
 $j^* := \arg \max_{s:s \leq j} Q(f_s)$;
- 12: **если** $j - j^* \geq d$ **то вернуть** f_{j^*}

Основные параметры алгоритма взяты в соответствии с рекомендациями из [8]: $r=19$, $T=30$, $h = \frac{1-p_{\min}}{rn}$, при $p_{\min} = \frac{1}{10n}$
 $h = 8.3333 \cdot 10^{-5}$. Минимальное число признаков j_0 выбрано равным 50, критерий останова $d = 20$.

Сложность алгоритма оценивается как $O(Tr(j^*+d))$, т.е. при заданных T , r , d зависит от искомого значения оптимальной сложности модели. В худшем случае (при $j^*=n$) трудоёмкость составляет $O(Tr(n+d))$ без учёта сложности алгоритма вычисления критерия Q .

Результаты применения алгоритма к построенному в работе признаковому пространству приведены в таблице 5.

Таблица 5.

Результаты выделения информативного подмножества признаков с помощью алгоритма СПА.

Размерность пространства признаков	Преобразования	Процент ошибок на контроле		
		SVM	GBT	RTF
192	$B3(C2(I)), B7(C2(I)), B8(C2(I)), B9(C2(I)), B10(C2(I)), B3(C5(I)), B3(C5(I)), B7(C5(I)), B8(C5(I)), B9(C5(I)), B10(C5(I)), C3(B2(I)), C3(B3(I)), C3(B6(I)), C5(B2(I)), C5(B3(I)), C7(B3(I)), C9(B3(I))$	4%	2%	2%

	<i>C9(B5(I)), C12(B3(I)), C12(B5(I)), C12(B10(I))</i>			
--	---	--	--	--

Анализ результатов

На основе описанных алгоритмов классификации и извлечения признаков разработана программа на языке программирования С# с применением известной открытой библиотеки компьютерного зрения OpenCV.

Программа использовалась в работе лаборатории лавинных и селевых процессов сахалинского филиала ДВГИ в зимний сезон 2012/2013 гг.

По итогам сезона было проведено сравнение результатов работы программы с экспертной оценкой текстуры снежной толщи. Всего было отобрано 520 фотографий участков стенки снежного шурфа. При этом программа показала 4% ошибок.

Анализ ошибок алгоритма на всей выборке выявил одну важную особенность. Все ошибочно классифицированные образцы расположены на границах соседних классов (типов текстуры). Т.е., в выборке не нашлось ни одного образца монолитной текстуры, который был бы классифицирован как образец волокнистой текстуры, и наоборот, ни один образец волокнистой текстуры не классифицирован как образец монолитной текстуры. Визуальный анализ ошибочно распознанных образцов показал, что большинство из них можно отнести разряду спорных, т. е. данные образцы с одинаковой вероятностью относятся к одному из соседних классов. Таким образом, можно заключить, что оценка качества классификации построенного алгоритма в действительности выше оценки, полученной при отложенном контроле после обучения алгоритма.

Заключение

Разработан алгоритм определения типа текстуры снежного слоя по фотографии соответствующего участка стенки снежного шурфа. Алгоритм включает два бинарных классификатора. Первый классификатор принимает решение, является ли фотография фотографией монолитной текстуры. При отрицательном ответе второй классификатор решает, является ли фотография фотографией столбчатой или волокнистой текстуры.

Признаковое описание текстуры снежного слоя на фотографии построено, исходя из анализа взаимного расположения кластеров ледяных кристаллов и порового пространства.

Оптимальное подмножество признаков построено с применением алгоритма случайного поиска с адаптацией.

Разработана программа для определения типа текстуры по фотографиям участка стенки шурфа. Программа прошла апробацию в работе лаборатории лавинных и селевых процессов сахалинского филиала ДВГИ.

Литература

1. Гляциологический словарь / Под ред. В.М. Котлякова. Л.: Гидрометеоиздат, 1984. 527с.
2. N.A. Kazakov, J.V. Gensiorovskiy, S.P. Zhiruev, M.S. Drevilo. "The stratigraphic complexes of a snowpack", *Annals of Glaciology*, 53(61), 2012.
3. Вапник В. Н. Восстановление зависимостей по эмпирическим данным. – М.: Наука, 1979. – 448с.
4. J. Friedman. "Greedy Function Approximation: A Gradient Boosting Machine", *The Annals of Statistics*, Vol. 29, No. 5, 2001.
5. Hastie. T., Tibshirani R., Friedman J. Chapter 15. Random Forests // *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*. – 2nd ed. – Springer-Verlag, 2009. – 746p.
6. N. Otsu. "A Threshold Selection Method from Gray-Level Histograms" *IEEE Transactions on Systems, Man, and Cybernetics*, vol. 9, no. 1, pp. 62-66, 1979.
7. Гонсалес Р., Вудс Р. Цифровая обработка изображений. – М.: Техносфера, 2005.
8. Лбов Г.С. Методы обработки разнотипных экспериментальных данных. Новосибирск: Наука, 1981.

EMAIL: KONONOV-IA@YANDEX.RU

МОБ. ТЕЛ.: 89242804716